

**EEG VE EKG İŞARETLERİNDEN ÖRÜNTÜ TANIMA
UYGULAMALARI VE KARŞILAŞTIRILMASI**

Abdulnasır YILDIZ

Doktora Tezi

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Mustafa POYRAZ

HAZİRAN-2011

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EEG VE EKG İŞARETLERİNDEN ÖRÜNTÜ TANIMA UYGULAMALARI VE
KARŞILAŞTIRILMASI**

DOKTORA TEZİ

Abdulnasır YILDIZ

(02113209)

Anabilim Dalı: Elektrik-Elektronik Mühendisliği

Programı: Devreler ve Sistemler

Danışman: Prof. Dr. Mustafa POYRAZ

Tezin Enstitüye Verildiği Tarih: 18 Mayıs 2011

HAZİRAN-2011

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**


**EEG VE EKG İŞARETLERİNDEN ÖRÜNTÜ TANIMA UYGULAMALARI VE
KARŞILAŞTIRILMASI**

DOKTORA TEZİ

**Abdulnasır YILDIZ
(02113209)**

**Tezin Enstitüye Verildiği Tarih : 18 Mayıs 2011
Tezin Savunulduğu Tarih : 6 Haziran 2011**

Tez Danışmanı : Prof. Dr. Mustafa POYRAZ (F.Ü)



Diğer Jüri Üyeleri : Prof. Dr. M. Kemal KIYMIK (K.S.Ü)

Prof. Dr. Mehmet AKIN (D.Ü)



Prof. Dr. Yakup DEMİR (F.Ü)



Yrd. Doç. Dr. Melih C. İNCE (F.Ü)



HAZİRAN-2011

ÖNSÖZ

Bu tez çalışmam boyunca, ilgi ve yardımlarını esirgemeyen danışmanım Sayın Prof. Dr. Mustafa POYRAZ'a, yine her zaman beni destekleyen ve yardımlarını esirgemeyen Sayın Prof. Dr. Mehmet AKIN'a, çalışmada kullanılan EEG verilerinin alınması ve değerlendirilmesindeki yardımlarından dolayı Dicle Üniversitesi uyku laboratuvarı sorumlusu Sayın Doç. Dr. Gökhan KIRBAŞ'a, tezin düzenlenmesinde fikirlerinden faydalandığım Sayın Yrd. Doç. Dr. M. Bahattin KURT, Sayın Yrd. Doç. Dr. Davut HANBAY ve Sayın Yrd. Doç. Dr. Mustafa NALBANTOĞLU'na, destek ve yardımlarından dolayı Fırat ve Dicle üniversitelerinin Elektrik Elektronik Mühendisliği bölümü akademik ve idari personeline çok teşekkür ederim. Son olarak çalışmam süresince beni sabır ve özveri ile destekleyen sevgili aileme ayrıca teşekkür eder ve şükranlarımı sunarım.

Abdulnasır YILDIZ
ELAZIĞ – 2011

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	II
İÇİNDEKİLER	III
ÖZET	V
SUMMARY	VI
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ	XI
KISALTMALAR LİSTESİ	XIII
1. GİRİŞ	1
1.1. Çalışma Kapsamında Yapılan Literatür Taraması	3
1.2. Tez Çalışmasının Amacı ve İzlenen Yöntem	8
1.3. Tez Çalışmasının İçeriği	9
2. EEG ve UYKU	10
2.1. EEG	10
2.1.1. EEG Dalgaları	11
2.1.2. EEG İşaretlerinin Ölçülmesi	13
2.2. Uyku	14
2.2.1. Uyku Evreleri	16
2.2.2. Uyanıklık Seviyesi	17
3. EKG ve OBSTRÜKTİF UYKU APNE SENDROMU	19
3.1. EKG	19
3.1.1. EKG Dalgaları ve Aralıkları	20
3.1.2. EKG Ölçüm Yöntemleri	21
3.2. Obstrüktif Uyku Apne Sendromu	24
3.2.1. Polisomnografi Tanı Tekniği	25
3.2.2. Obstrüktif Uyku Apne Sendromu Tanısında EKG	27
4. ÖRÜNTÜ TANIMA	31
4.1. Örüntü Tanıma Sistemi	32
4.1.1. Özellik Belirleme	32
4.1.2. Sınıflandırma	33
4.2. Özellik Belirleme Yöntemleri	34
4.2.1. Dalgacık Dönüşümü	35
4.2.2. Güç Spektral Yoğunluk Kestirimi	40
4.2.3. Welch Yöntemi	41
4.2.4. Entropi Hesaplama Teknikleri	43
4.3. Sınıflandırma Yöntemleri	45
4.3.1. Yapay Sinir Ağları	46
4.3.2. ANFIS	59
4.3.3. Destek Vektör Makineleri	72
4.3.4. En küçük Kareler Destek Vektör Makineleri	81
5. EEG ve EKG İŞARETLERİNDE ÖRÜNTÜ TANIMA ve UYGULAMALARI	83
5.1. EEG İşaretlerinden Uyanıklık Seviyesini Tespit Eden Örüntü Tanıma Sistemi ve Uygulamaları	83

5.1.1.	EEG Verilerinin Toplanması	85
5.1.2.	EEG İşaret Örüntülerinden Özellik Çıkarma.....	86
5.1.2.1.	Dalgacık Dönüşümünden Entropi Hesaplanması	87
5.1.2.2.	Dalgacık Dönüşümü ve Welch GSY ile Entropi Hesaplanması.....	90
5.1.3	EEG İşaret Örüntülerini Sınıflandırma.....	94
5.1.3.1.	Yapay Sinir Ağları Tabanlı Sınıflandırma	95
5.1.3.2.	ANFIS Tabanlı Sınıflandırma	97
5.1.3.3.	En Küçük Karaler Destek Vektör Makine Tabanlı Sınıflandırma	100
5.2.	EKG İşaretlerinden OUAS Hastalığını Tespit Eden Örüntü Tanıma Sistemi ve Uygulamaları	101
5.2.1.	Kullanılan EKG Verileri.....	103
5.2.2.	Ön-işlem Süreci: EKG İşaretlerinden KHD ve ETS İşaretlerinin Elde Edilmesi.....	104
5.2.2.1	EKG işaretlerinin Dalgacık Dönüşümü ile Analizi	105
5.2.2.2.	QRS Dalgaları R Tepe Konumlarının Tespit Edilerek KHD ve ETS İşaretlerinin Hesaplanması	108
5.2.3.	KHD ve ETS İşaretlerinden Özellik Çıkarma	112
5.2.3.1.	Dalgacık Dönüşümünden Entropi Hesaplanması	113
5.2.3.2.	Dalgacık Dönüşümü ve Welch GSY ile Entropi Hesaplanması.....	118
5.2.4.	EKG Kayıtlarından Türetilen KHD ve ETS İşaret Örüntülerini Sınıflandırma	123
5.2.4.1.	Yapay Sinir Ağları Tabanlı Sınıflandırma	126
5.2.4.2.	En Küçük Kareler Destek Vektör Makine Tabanlı Sınıflandırma	128
6.	SONUÇ ve DEĞERLENDİRME	130
6.1.	Sonuçların Değerlendirilmesi	133
6.2.	Öneriler.....	137
	KAYNAKLAR	139
	ÖZGEÇMİŞ	

ÖZET

Uykuya ilişkin fizyolojik veya hastalıklı bir durumun değerlendirilmesinde kullanılan geleneksel Polisomnografi tekniği, karmaşıklığı ve maliyeti nedeniyle birtakım dezavantajlara sahiptir. Son zamanlarda bu tekniğe alternatif olarak, tanı ve değerlendirmede yeni otomatik tanı teknikleri üzerinde çalışılmaktadır.

Bu çalışmanın temel amaçlarından birincisi, uyanık durumdan uyku durumuna geçiş sürecinde kaydedilen Electroensefolagram (EEG) işaretlerinden, kişinin uyanıklık seviyesini tespit eden bir otomatik örüntü tanıma sistemi sunmaktır. Sunulan bu sistemde, EEG işaret örüntülerinin karakteristik özelliklerinin ortaya çıkarılması için Dalgacık Dönüşümü (DD) tabanlı iki ayrı özellik çıkarım yöntemi kullanılmıştır. Bu özellik çıkarım yöntemlerinin her birinin etkinliği, Yapay Sinir Ağları (YSA), En Küçük Kareler Destek Vektör Makineleri (EKK-DVM) ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive neuro-fuzzy Inference System (ANFIS)) sınıflandırıcıları üzerinde test edilmiştir. Uyanıklık seviyesinin tespiti için kullanılan bu altı farklı sınıflandırma yaklaşımının performans karşılaştırılması yapılmıştır.

Bu çalışmanın ikinci temel amacı ise kişinin gece boyunca alınan Elektrokardiyogram (EKG) kaydından, önemli bir halk sağlığı problemi olan, Obstruktif Uyku Apne Sendromu (OUAS) hastası olup olmadığını belirleyen bir otomatik örüntü tanıma sistemi sunmaktır. Bu sistemde öncelikle DD analizine dayalı bir algoritma kullanılarak, EKG kaydından Kalp Hız Değişkenliği (KHD) ve EKG'den Türetilen Solunum (ETS) işaretleri hesaplanmıştır. Daha sonra gerek KHD ve gerekse ETS işaretlerinin karakteristik özelliklerinin ortaya çıkarılması için yine DD tabanlı iki ayrı özellik çıkarım yöntemi kullanılmıştır. Sistemin sınıflandırma kısmında ise biri YSA, diğeri ise EKK-DVM olmak üzere iki farklı sınıflandırıcı kullanılmıştır. Bu otomatik örüntü tanıma sistemi ile EKG kayıtlarından kişinin OUAS hastası olup olmadığının tespiti için on iki farklı sınıflandırma yaklaşımı yapıp, bu yaklaşımların test performans sonuçları karşılaştırılmıştır.

Ayrıca bu tezde sunulan her iki sistem, performans açısından literatürdeki benzer çalışmalar ile kıyaslanmıştır.

Anahtar Kelimeler: Uyanıklık Seviyesi, Obstruktif Uyku Apne Sendromu (OUAS), EEG, EKG, Kalp Hızı Değişkenliği (KHD), EKG'den Türetilen Solunum (ETS), Örüntü Tanıma, Dalgacık Dönüşümü (DD), En Küçük Kareler Destek Vektör Makineleri (EKK-DVM), Yapay Sinir Ağları (YSA), Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS).

SUMMARY

Applications and Comparison of Pattern Recognition from EEG and ECG Signals

Traditional polisomnograph technique, used in assessing any statements related with sleep, has several disadvantages due to its complexness and cost. Currently newer automatic diagnostic technique are studied in diagnose and assessment as an alternative to it.

One of the main aims of this study is presenting an automatic pattern recognition system for estimation vigilance level by using Electroencephalogram (EEG) signals recorded during transition from alert to sleep cases. In this system two different feature extraction methods based on Wavelet transform (WT) were used to detect the characteristics of EEG signals. Forcefulness of each feature extraction methods were tested on Artificial Neural Network (ANN), Least Squares Support Vector Machine (LS-SVM) and Adaptive neuro-fuzzy Inference System (ANFIS) classifiers. Also, performance comparison of six different classification approaches used for detection of vigilance level was done.

The other main aim of this thesis is to present an automatic pattern recognition system for the automatic recognition of patients with Obstructive Sleep apnea syndrome (OSAS) from nocturnal Electrocardiogram (ECG) recordings. In this system, Heart rate variability (HRV), and ECG derived respiration (EDR) signals were obtained using an algorithm based on WT. Then two different feature extraction methods were used to determine the characteristics of both HRV and EDR signals. In the classification section of this system two different classifiers, which were ANN, and LS-SVM, were used. Twelve different classification approaches were done for detecting the situation of patients whether they have OSAS or not from ECG recordings by using this automatic pattern recognition system. In addition all the test performance results of these classification approaches were compared.

Consequently, the systems presented in this thesis were compared with similar studies in the literature from the viewpoint of performance.

Key Words: Vigilance Level, Obstructive Sleep Apnoea Syndrome (OSAS), EEG, ECG, Heart Rate Variability (HRV), ECG-derived Respiration (EDR), Pattern Recognition, Wavelet Transform (WT), Least Squares Support Vector Machines (LS-SVM), Artificial Neural Network (ANN), Adaptive Neuro-Fuzzy Inference Systems (ANFIS)

ŞEKİLLER LİSTESİ

Şekil 2.1.	Delta dalgası.....	11
Şekil 2.2.	Teta dalgası.....	11
Şekil 2.3.	Alfa dalgası.....	12
Şekil 2.4.	Beta dalgası.....	12
Şekil 2.5.	Gama dalgası.....	12
Şekil 2.6.	Beyin-bilgisayar arabirimi.....	13
Şekil 2.7.	Uluslararası 10–20 EEG elektrot yerleştirme sistemi.....	14
Şekil 2.8.	Polisomnografide EEG, EOG ve EMG kaydı.....	15
Şekil 2.9.	Uyanıklık seviyesinin 3 farklı durumunu tanımlayan gösterim.....	18
Şekil 3.1.	Normal EKG işareti.....	20
Şekil 3.2.	EKG derivasyonlarının elektrot yerleşim biçimi: a) Çift kutuplu kol bacak derivasyonları b) Tek kutuplu kol bacak derivasyonları c) Tek kutuplu göğüs derivasyonları	23
Şekil 3.3.	Module edilen EKG işareti ve solunum işaretinin 10 saniyelik kayıtları.....	29
Şekil 4.1.	Bir örüntü tanıma sisteminin blok diyagram.....	32
Şekil 4.2.	Fourier Dönüşümü.....	35
Şekil 4.3.	Kısa Zamanlı Fourier Dönüşümü.....	35
Şekil 4.4.	İşaretin Dalgacık Dönüşümü analizi.....	36
Şekil 4.5.	Yaygın olarak kullanılan ana dalgacık fonksiyon örnekleri.....	36
Şekil 4.6.	ADD ile işaretin alt bantlara ayrıştırılması.....	39
Şekil 4.7.	Orijinal işaretin yeniden oluşturulması.....	39
Şekil 4.8.	Pencere fonksiyonları.....	43
Şekil 4.9.	Termodinamik ve işaret işleme açısından a) Düşük, b) Yüksek entropi.....	44

Şekil 4.10.	Bir yapay hücre modeli.....	47
Şekil 4.11.	YSA için aktivasyon fonksiyonları: (a) basamak, (b) doğrusal, (c) log-sigmoid, (d) tan-sigmoid.....	48
Şekil 4.12.	ÇKA modeli.....	52
Şekil 4.13.	Boy uzunlukları için klasik kümeler.....	61
Şekil 4.14.	Boy uzunlukları için bulanık kümeler.....	62
Şekil 4.15.	Çeşitli üyelik fonksiyonları.....	64
Şekil 4.16.	Bulanık tabanlı bir sistemin genel yapısı.....	65
Şekil 4.17.	Giriş değişkenleri için üyelik fonksiyonları: a) hata, b) hatadaki değişim.....	65
Şekil 4.18.	Çıkış değişkeni için üyelik fonksiyonları.....	67
Şekil 4.19.	İki girişli ve iki kurallı ANFIS yapısı.....	69
Şekil 4.20.	Doğrusal olarak ayrılabilen veri kümesi için DVM sınıflandırıcısı.....	74
Şekil 4.21.	Doğrusal olarak belirli bir hata ile ayrılabilen veri kümesi için DVM sınıflandırıcısı.....	77
Şekil 4.22.	Giriş uzayını yüksek boyutlu özellik uzayına haritalama.....	79
Şekil 5.1.	EEG işaretlerinden uyanıklık seviyesine tespit eden örüntü tanıma sistemi.....	84
Şekil 5.2.	Üç farklı duruma ait EEG işaretleri: (a) Uyanık, (b) uyuklama, (c) uyku....	86
Şekil 5.3.	EEG işareti için DD bileşenlerinin entropisi ile özellik çıkarımın blok diyagramı.....	87
Şekil 5.4.	(a) uyanık, (b) uyuklama ve (c) uyku EEG işaretlerinin 4. seviyeden DD'leri.....	88
Şekil 5.5.	(a) uyanık, (b) uyuklama ve (c) uyku EEG işaretlerinin DD-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.....	90
Şekil 5.6.	EEG işareti için DD ve Welch GSY kestirimi entropileri ile özellik çıkarımın blok diyagramı.....	91
Şekil 5.7.	(a) uyanık, (b) uyuklama ve (c) uyku EEG işaretlerine ilişkin D_2 , D_3 , D_4 katsayılarının Welch yöntemi ile elde edilen GSY'leri.....	93

Şekil 5.8.	(a) uyanık, (b) uyuklama ve (c) uyku EEG işaretlerinin DD-WGSY-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.....	94
Şekil 5.9.	(a) DD-EH ve (b) WGSY-EH özellik çıkarım yöntemlerine göre YSA tabanlı sınıflandırıcının eğitim performansı.....	97
Şekil 5.10.	ANFIS tabanlı sınıflandırıcı.....	98
Şekil 5.11.	(a) DD-EH ve (b) WGSY-EH özellik çıkarım yöntemlerine göre ANFIS tabanlı sınıflandırıcının eğitim performansı.....	99
Şekil 5.12.	EKG işaretlerinden OUAS hastalığını tespit eden örüntü tanıma Sistemi.....	102
Şekil 5.13.	Bir dakikalık orijinal EKG işareti ve bu işaretin 7. seviyeden DD ayrıştırması.....	106
Şekil 5.14.	(a) Orijinal EKG işareti, (b) THSA-EKG işareti.....	107
Şekil 5.15.	Yaklaşık 8 saat süreli bir EKG kaydından elde edilen ETS işareti.....	110
Şekil 5.16.	Yaklaşık 8 saat süreli bir EKG kaydından elde edilen KHD işareti.....	110
Şekil 5.17.	EKG kaydına ait örneklenmiş ve normalize edilmiş KHD işareti.....	112
Şekil 5.18.	EKG kaydına ait örneklenmiş ve normalize edilmiş ETS işareti.....	112
Şekil 5.19.	KHD ve ETS işaretleri için DD bileşenlerinin entropisi ile özellik çıkarımın blok diyagramı.....	113
Şekil 5.20.	(a) Normal ve (b) OUAS'lı KHD işaretlerinin 12. seviyeden DD'leri.....	115
Şekil 5.21.	(a) Normal ve (b) OUAS'lı ETS işareti lerinin 12. seviyeden DD'leri.....	116
Şekil 5.22.	(a) Normal ve (b) OUAS'lı KHD işaretlerinin DD-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.....	117
Şekil 5.23.	(a) Normal ve (b) OUAS'lı ETS işaretlerinin DD-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.....	118
Şekil 5.24.	KHD ve ETS işaretleri için DD ve Welch GSY kestirimi entropileri ile özellik çıkarımın blok diyagramı.....	118

Şekil 5.25.	(a) Normal ve (b) OUAS'lı KHD işaretlerinin DD katsayılarına ilişkin hesaplanan GSY'ler.	120
Şekil 5.26.	(a) Normal ve (b) OUAS'lı ETS işaretlerinin DD katsayılarına ilişkin hesaplanan GSY'ler.	121
Şekil 5.27.	(a) Normal ve (b) OUAS'lı KHD işaretlerinin DD-WGSY-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.	123
Şekil 5.28.	(a) Normal ve (b) OUAS'lı ETS işaretlerinin DD-WGSY-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.	123

TABLÖLER LİSTESİ

Tablo 3.1.	AHI'e göre OUAS Sınıflaması.....	27
Tablo 4.1.	İşaret işleme alanında yaygın kullanılan entropi türleri ve bu entropi türlerine ait denklemler.....	45
Tablo 4.2.	$e=30$ ve $\delta e=-15$ giriş değerleri için bulandırma sonuçları.....	66
Tablo 4.3.	Kural tabanı.....	67
Tablo 4.4.	Yaygın olarak kullanılan çekirdek fonksiyonları.....	80
Tablo 5.1.	DD ayrışımındaki frekans bantlarının aralıkları.....	88
Tablo 5.2.	Özellik çıkarım ve sınıflandırıcı kombinasyonları.....	94
Tablo 5.3.	Eğitim veri kümesi ve test veri kümesi detayı.....	95
Tablo 5.4.	Kullanılan YSA modelinin yapısı ve eğitim parametreleri.....	96
Tablo 5.5.	Kullanılan özellik çıkarım yöntemine göre YSA sınıflandırıcı modelin EEG işaret örüntülerini tanıma başarımı.....	97
Tablo 5.6.	Kullanılan özellik çıkarım yöntemine göre ANFIS tabanlı sınıflandırıcının EEG işaret örüntülerini tanıma başarımı.....	100
Tablo 5.7.	Kullanılan özellik çıkarım yöntemine göre EKK-DVM sınıflandırıcı modelin EEG işaret örüntülerini tanıma başarımı.....	101
Tablo 5.8	EKG işaretinin DD ayrışımındaki frekans bantlarının aralıkları.....	105
Tablo 5.9.	EKG'den OUAS tespitini yapan 12 farklı örüntü sınıflandırma yaklaşımının kullanılan EKG kaydına ilişkin işaret türü, özellik çıkarım yöntemi ve sınıflandırıcı yöntemine göre gösterimleri.....	124
Tablo 5.10.	Konfüzyon matrisi.....	126
Tablo 5.11.	Kullanılan YSA modelinin yapısı ve eğitim parametreleri.....	127
Tablo 5.12.	YSA tabanlı her sınıflandırma yaklaşımının OUAS'ı tespit etmedeki başarımının konfüzyon matrisi ile gösterimi.....	127
Tablo 5.13.	YSA tabanlı her sınıflandırma yaklaşımının istatistiksel parametreler hesabına göre test performansı sonuçları.....	128

Tablo 5.14.	EKK-DVM tabanlı her sınıflandırma yaklaşımının OUAS'ı tespit etmedeki başarımının konfüzyon matrisi ile gösterimi.....	129
Tablo 5.15.	EKK-DVM tabanlı her sınıflandırma yaklaşımının istatistiksel parametreler hesabına göre test performansı sonuçları.....	129
Tablo. 6.1.	EEG'den uyanıklık seviyesini tespit eden 6 sınıflandırma yaklaşımının her birinin test veri seti üzerindeki başarımları.....	131
Tablo. 6.2.	EKG'den kişinin OUAS hastası olup olmadığını tespit eden 12 sınıflandırma yaklaşımının her birinin test veri seti üzerindeki başarımları.....	133

KISALTMALAR LİSTESİ

ADD	Ayrık Dalgacık Dönüşümü
AFD	Ayrık Fourier Dönüşümü
AHI	Apne Hipopne İndeksi
ANFIS	Adaptive Neuro-Fuzzy Inference Systems (Uyarlamalı Sinirsel Bulanık Çıkarım Sistemleri)
CPAP	Continuous Positive Airway Pressure (Sürekli Pozitif Hava Basıncı)
ÇKA	Çok Katmanlı Algılayıcı
Db	Daubechies
DD	Dalgacık Dönüşümü
DD-EH	Dalgacık Dönüşümünden Entropi Hesaplama
DD-WGSY-EH	Dalgacık Dönüşümü ve Welch GSY ile Entropi Hesaplanması
DVM	Destek Vektör Makine
EDR	ECG-Derived Respiration (EKG'den türetilen Solunum)
EEG	Elektroensefolagram / Elektroensefalografi
EKG	Elektrokardiyogram / Elektrokülografi
EKK-DVM	En Küçük Kareler- Destek Vektör Makineleri
EMG	Elektromyogram / Elektromyografi
EOG	Elektrokülogram / Elektrokülografi
ETS	EKG'den Türetilen Solunum
FD	Fourier Dönüşümü
GSY	Güç Spektral Yoğunluk
HFD	Hızlı Fourier Dönüşümü
KHD	Kalp Hız Değişkenliği
KZFD	Kısa Zamanlı Fourier Dönüşümü
LVQ	Learning Vector Quantization (Doğrusal Vektör Parçalama)
OUAS	Obstruktif Uyku Apne Sendromu
PSG	Polisomnografi
ROC	Receiver Operating Curve (Alıcı İşletme Eğrileri)
SDD	Sürekli Dalgacık Dönüşümü
SOM	Self Organizing Maps (Kendinden Organize Haritalar)
THSA-EKG	Taban Hattı Sapmasından Arındırılmış EKG
YSA	Yapay sinir Ağları

1. GİRİŞ

Uyku, insan yaşamının önemli bir kısmını kapsamı ve bu kısmın kiři sağığı ve günlük yaşam kalitesi üzerindeki etkileri nedeniyle, günümüzde uyku tıbbı adı altında farklı bir disiplin olarak incelenmektedir. Bu disiplin; kiři sağığını bozan, günlük yaşamdaki bilişsel ve fiziksel performansını düşüren ve bunun sonucunda birçok iş ve trafik kazalarına sebebiyet vererek, can ve mal kaybına neden olan uykuya ilişkin hastalıkların tanı ve tedavisiyle uğraşır. Amerika Uyku Tıbbı Akademisi'nin 2005 yılı verilerine göre 80'nin üzerinde uyku hastalığı türü bulunmaktadır [1]. Bu hastalık türleri arasında insan sağığı açısından taşıdığı riskler nedeniyle en önemlilerinden biri Obstruktif Uyku Apne Sendromu (OUAS) hastalığıdır. OUAS, uyku sırasında tekrarlayan tam (apne) veya kısmi (hipopne) üst solunum yolu tıkanma atakları, kan oksijen satürasyonunda oluşan azalma ve uyanma dönemleri ile karakterize bir hastalıktır [2]. OUAS'ın, erkeklerin %4'ünde, kadınların %2'sinde görüldüğü tahmin edilmektedir [3]. OUAS olan hastalarda, solunum yolu tıkanmaları sebebiyle düzenli ve yeterli bir uyku alınamadığından gündüz aşırı uykululuk hali görülür. Bu aşırı uykululuk halinin, fiziksel ve bilişsel performans düşüklüğüne, hafıza kaybına, depresyona ve bunlarla ilişkili iş ve trafik kazaları risk artışına sebebiyet verdiği görülmüştür [4, 5]. Ayrıca OUAS'ın, kardiyovasküler hastalıkların (hipertansiyon, kardiyak aritmi, miyokard infarktüs, inme v.s) gelişmesinde önemli bir risk faktörü olduğu belirtilmiştir [6, 7]. Dolayısıyla insan sağığını olumsuz etkileyen bu hastalığın erken tanı ve tedavisi büyük önem taşımaktadır.

Polisomnografi (PSG), OUAS'ın teşhisinde kullanılan altın standart bir tekniktir [8, 9]. Hastanelerin uyku laboratuvarlarında gerçekleştirilen ve uyku çalışması olarak da bilinen bu teknik ile OUAS şüphelisi kişiden gece boyunca eş zamanlı alınan çeşitli kayıtlar (EEG, EOG, EMG, EKG, ağız-burun hava akımı, göğüs-karın solunum hareketleri, oksijen satürasyonu v.s) uzman kişilerce değerlendirildikten sonra tanı konulmaktadır. OUAS için en objektif tanı yöntemi uyku çalışma tekniğı olmasına rağmen bu çalışma tekniğinin oldukça karmaşık, pahalı ve zaman alıcı olduğu da bilinmektedir. Ayrıca uyku çalışma tekniğinin uygulandığı laboratuvarların gerek ülkemizde ve gerekse diğer dünya ülkelerinde yeterli sayıda olmadığı da bilinen diğer bir gerçektir [6, 10]. Bu da OUAS tanısı için uyku çalışma tekniğine alternatif oluşturabilecek ucuz, daha az kayıt gerektiren, güvenilir ve aynı zamanda laboratuvar ortamında değil de ev ortamında uygulanabilecek tanı

tekniklerine ihtiyaç duyulduğunu göstermektedir. Sadece Elektrokardiyogram (EKG) kayıtları kullanılarak geliştirilebilecek bir tanı tekniği ile bu ihtiyaçları gidermek mümkün olabilir.

Bu tez çalışmasının amaçlarından biri, gece boyunca alınan EKG kayıtlarından kişinin OUAS hastası olup olmadığını tespit edebilen otomatik bir örüntü tanıma sistemi sunmaktır.

Gündelik yaşam içerisinde uykuya olan meyil veya başka bir ifadeyle uyku olma hali (uyuklama), OUAS'ın da dahil olduğu uykuya ilişkin birçok hastalığın ortak bir sonucudur. Bu durum, gündelik iş yaşamının getirdiği yorgunluk ve normal uykuya yeterli zaman ayıramamanın bir sonucu olarak da görülebilmektedir. Uyuklama, normal şartlarda gece uykusu öncesi yaşanan ve uykuya zeminin hazırlandığı kısa süreli bir süreçtir [11, 12]. Bu süreç esnasında, aktif uyanık duruma göre kişinin fiziksel ve zihinsel performansı zayıflar. Bu durum kişinin dış uyaranlara karşı, özellikle hayati derecede önemli olan bazı acil durumlar karşısında, hızlı ve anlamlı tepki verebilme yeteneğinin azalması anlamına gelmektedir. Özellikle ulaştırma ve endüstriyel alanlarda, aşırı dikkat isteyen, uzun süreli ve monoton birçok iş kolunda meydana gelen kazaların bir kısmının, kişinin yorgunluk ve uyuklama sebebiyle uyanıklık (dikkat) düzeyinde görülen düşüşten kaynaklandığı bildirilmektedir [13, 14]. Bu iş kollarında bu sebeple oluşan kazalar ciddi anlamda can ve mal kaybına neden olmaktadır. Bu ciddi sonuçlar, kişinin uyanıklık seviyesini tespit edebilen otomatik uyarı sistemlerine ihtiyaç duyulduğunu göstermektedir.

Günümüzde, uyanıklık seviyesinin değerlendirilmesinde kabul gören en objektif metod, vücut yüzeyinden eş zamanlı kaydedilen beynin elektriksel aktivitesi olan Elektroensefolagram (EEG), kasın elektriksel aktivitesi olan Elektromyogram (EMG) ve gözlerin elektriksel aktivitesi olan Elektrookülogram (EOG) işaretlerinin birlikte analizine dayanmaktadır. Bu işaretler içerisinde EEG uyanıklık seviyesinin değerlendirmesinde kullanılan en önemli biyolojik işarettir [11, 12, 15, 16].

Bu tez çalışmasının diğer bir amacı da kişinin dikkat seviyesini, bir başka ifadeyle uyanıklık seviyesini beyninin elektriksel aktivitesi olan EEG işaretinden tespit eden otomatik bir sistem sunmaktır.

1.1. Çalışma Kapsamında Yapılan Literatür Taraması

Beynin elektriksel aktivitesi olan EEG işareti kişinin uyanıklık seviyesinin değerlendirilmesinde kullanılabilecek en güvenilir ve belirleyici araç olarak bilinir. Bu, EEG'nin her farklı fizyolojik durum (uyanık, uyuklama ve uyku) için kendine has farklı karakteristik ritmik özellikler sergileyebilmesinden kaynaklanır [11, 12, 16].

EEG işaretlerinin dinamik ve durağan olmayan rastgele işaretler olması, bu işaretlerin geleneksel yöntemlerle (uzman kişilerce görerek değerlendirme) analizini güçleştirir [17, 18, 19]. Ayrıca geleneksel analiz yönteminde EEG konusunda uzman kişilere gereksinim duyulması ve bu uzman kişilerin görerek yaptıkları değerlendirmelerin oldukça zaman alıcı olduğu da bilinmektedir [18]. EEG işaretlerinin değerlendirilmesinde karşılaşılan bu tür dezavantajların üstesinden gelebilmek için literatürde bilgisayar tabanlı modern yöntemler kullanarak, EEG işaretinden beyin aktivitesinin karakteristik özelliklerini ortaya çıkaran ve bu özellikler üzerinden kişinin fizyolojik durumunun kestirimini otomatik olarak yapan çalışmalar gerçekleştirilmiştir. Bu bağlamda yapılan çalışmaların bir kısmı aşağıda özetlenmiştir.

Literatürde, Fourier Dönüşümü (FD) tabanlı özellik çıkarım teknikleri ile yapay zeka tabanlı sınıflandırıcı tekniklerini birlikte kullanarak EEG'den uyanıklık seviyesini otomatik olarak tespit eden bazı çalışmalar yapılmıştır [18, 20-24]. Bu çalışmalardan birinde, EEG'nin Hızlı Fourier Dönüşümü (HFD) tabanlı spektral özellikleri üzerinden kişinin uyanıklık seviyesinin otomatik tespiti için bir Yapay Sinir Ağları (YSA) modeli olan çok katmanlı algılayıcı sınıflandırıcısı kullanılmıştır [21]. Bir başka çalışmada [18] ise çok kanallı EEG'nin 1'er saniyelik bölütlere ayrılmış zaman serilerinin çapraz spektral yoğunlukları YSA'nın LVQ modeli girişine verilerek kişinin uyanıklık seviyesi uyanık ve uyuklama olarak iki sınıfa ayrıştırılmıştır. Diğer bir çalışmada [24], 10'ar saniyelik EEG bölütlerinin HFD tabanlı güç spektral yoğunluk özellikleri üzerinden kişinin uyanıklık seviyesini, uyanık ve uyuklama olarak sınıflandırabilmek için sınıflandırıcı olarak Destek Vektör Makineleri (DVM) kullanılmıştır. Bir diğer çalışmada [23] çok kanallı EEG'nin HFD tabanlı spektral özelliklerine YSA'nın SOM ve LVQ modellerinin birleşiminden oluşan bir sınıflandırıcı uygulanarak, uyanıklık seviyesi uyku ve uyuklama olarak sınıflandırılmıştır. Belirtilen çalışmalardan farklı olarak bir başka çalışmada [25] ise 5'er saniyelik EEG bölütlerine uygulanan HFD tabanlı ve model tabanlı (AR, MA, ARMA) 4 ayrı güç spektral yoğunluk kestirim yönteminin uyanıklık seviyesini, uyanık, uyuklama ve

uyku olarak tespit etmedeki etkinliklerinin karşılaştırılması yapılmıştır. Bu karşılaştırma sonucunda model tabanlı AR ve ARMA yöntemleri ile elde edilen spektral bilginin, uyanıklık seviyesinin tespitinde daha etkin olabileceği vurgusu yapılmıştır. Yine bir başka çalışmada [26] ise EEG'nin fraktal boyut özellikleri ile Kısa Zamanlı Fourier Dönüşümü (KZFD) tabanlı özelliklerinin uyanıklık seviyesini uyanık, uyuklama ve uyku olarak tespit etmedeki etkinlikleri karşılaştırılmıştır.

EEG'den uyanıklık seviyesinin otomatik tespitine yönelik yapılan bazı çalışmalarda ise EEG işaret analizi için bir zaman-frekans analiz yöntemi olan Dalgacık Dönüşümü (DD) kullanılmıştır [19, 27-30]. Bu çalışmalardan birinde [19], DD kullanılarak EEG'nin 5'er saniyelik bölütleri bazı karakteristik alt bantlarına ayrıştırılmış. Daha sonra, bu karakteristik alt bantların hesaplanan güç spektral yoğunlukları bir YSA sınıflandırıcı girişine verilerek uyanıklık seviyesi; uyanık, uyuklama ve uyku olarak üç sınıfa ayrıştırılmıştır. Bu çalışmanın test veri kümesi üzerindeki toplam sınıflandırma doğruluğu %95'in üzerinde olmuştur. Benzer bir başka çalışmada [28], EEG'nin DD ile elde edilen karakteristik alt bantlarının hesaplanan bazı istatistiksel değerleri (en küçük, en büyük, standart sapma, ortalama) bir YSA sınıflandırıcısının girişi olarak kullanılmıştır. Sınıflandırıcının test veri kümesi üzerinden uyanıklık seviyesini uyanık, uyuklama ve uyku olarak sınıflandırmadaki başarımı %92'nin üzerinde olmuştur. Bir başka çalışmada [30], EEG'nin DD tabanlı özellikleri ile fraktal boyut tabanlı özelliklerinin uyanıklık seviyesini tespit etmedeki etkinlikleri karşılaştırılmıştır. Bu karşılaştırma, DVM sınıflandırıcısı üzerinde test edilmiştir. Test sonucunda, EEG'nin DD tabanlı özelliklerinin uyanıklık seviyesinin tespitinde daha etkin olduğu belirtilmiştir.

Literatürde EEG, EOG ve EMG kayıtlarını birlikte kullanarak uyanıklık seviyesini otomatik olarak tespit eden çalışmalar da mevcuttur [31,32]. Bu çalışmalardan birinde [31], EEG'nin DD ile elde edilen alt bantlarına ilişkin katsayılar ve filtrelenmiş EMG işareti bir YSA sınıflandırıcının girişleri olarak seçilmiştir. Girişleri bu şekilde oluşturulan sınıflandırıcının uyanıklık seviyesini uyanık, uyuklama ve uyku olarak sınıflamadaki test başarımının % 98'in üzerinde olduğu belirtilmiştir.

Bu bölümde, yukarıda verilen literatür çalışması bu tez çalışmasının konularından biri olan EEG'den uyanıklık seviyesinin tespitine yöneliktir. Bölümün bundan sonraki kısmında verilecek olan literatür çalışması ise bu tez çalışmasının diğer bir konusu olan EKG kayıtlarından OUAS hastalığının tespitine yöneliktir.

Literatürdeki bazı çalışmalar, kalbin elektriksel aktivitesi olan EKG kayıtlarından türetilen bazı bilgilerin OUAS hastalığının tanısında kullanılabileceğini göstermektedir. Bunlardan biri, Kalp Hızı Değişkenliği (KHD) olarak da adlandırılan EKG ‘nin ardışıl R-R aralıkları (kalp hızı) değişkenliğidir. **Guilleminault vd. (1984)**, EKG kayıtlarından türetilen R-R aralıkları işaretinin, OUAS’ın değerlendirilmesinde kullanılabileceği önerisinde bulunmuşlardır [33]. Bu öneri, OUAS’lı EKG kayıtlarının solunum tıkanmaları (apne) esnasında R-R aralıklarında gözlemlenen periyodik değişimlere dayandırılmıştır. Bu değişimler, apnenin ilk dönemlerinde oluşan bradikardi (kalp hızı yavaşlaması) ve apne sonrası ortaya çıkan taşikardi (kalp hızı artması) ile ilişkilendirilmiştir [33-36].

KHD’nin yanı sıra solunum mekanizmasının EKG kayıtları üzerinde oluşturduğu genlik modülasyonu bilgisinin EKG kayıtlarından türetilmesi durumunda, bu bilginin de OUAS’ın değerlendirilmesinde kullanılabileceğini öneren çalışmalar yapılmıştır [37, 38]. Bu çalışmalar solunum kaynaklı bu bilginin, EKG’nin her QRS dalgasının belirlenen bir pencere içerisinde kalan alan ölçümlerinden elde edilebileceğini göstermişlerdir. EKG’den bu şekilde elde edilen bilgi, solunum işaretinin dolaylı bir gösterimi olduğundan “ECG-Derived Respiration (EDR) signal” olarak adlandırılır. Bu tez çalışmasında ise “EDR signal’in” Türkçe karşılığı olarak “EKG’den türetilen solunum (ETS) işareti” tabiri kullanılmıştır.

Yukarıda belirtilen ilk çalışmaların ortaya koyduğu sonuçlarla birlikte, özellikle son 10 yıldır EKG kayıtlarından OUAS’ın otomatik tespitine yönelik çok sayıda çalışma yapılmıştır. Bu çalışmalardan dikkate değer olanların bir kısmı aşağıda özetlenmiştir:

Penzel vd. (2002), EKG kayıtlarının dakika bazında OUAS içerip içermediğini tespit eden 13 farklı algoritmanın sistematik karşılaştırılmasını yapmışlardır. Bu karşılaştırma sonucunda en iyi algoritmaların, genelde EKG’nin R-R aralıkları değişkenliği (KHD) ve solunum kaynaklı genlik değişimleri bilgilerinin frekans uzayındaki özelliklerini kullanan algoritmalar olduğunu ifade etmiştir. Bu algoritmalarından ikisinin test veri kümesi üzerindeki başarımlarının performansı %90 civarındadır [39].

Roche vd. (2003), EKG’den türetilen KHD işaretlerinin DD kullanılarak hesaplanan zaman-frekans parametrelerinin, OUAS’ın tanısında güçlü bir araç olarak kullanılabileceğini gösteren bir çalışma yapmışlardır. Bu çalışmada KHD işaretleri DD ile 8. seviyeden alt bantlarına ayrıştırılmış ve daha sonra her detay alt bandının güç değişkenliği, ilgili alt banda ait katsayıların toplamının karesinin hesaplanması ile elde edilmiştir. Bu şekilde temsil edilen alt bantların her birinin OUAS’ı tespit etmedeki

etkinliğinin testi için ise ROC analiz yöntemine başvurulmuştur. Bu analiz sonucunda birbirini izleyen düşük frekanslı alt bantların, yüksek frekanslı alt bantlara göre OUAS'ı tespit etmede daha etkin olduğu vurgusu yapılmıştır [40].

De Chazal vd. (2003), EKG kayıtlarından OSAS'ın tespitini yapan otomatik bir sistem geliştirmişlerdir. Geliştirilen sistem ön işlem, özellik çıkarım ve sınıflandırma olmak üzere üç temel aşamadan oluşmaktadır. Ön işlem aşaması EKG'den R-R aralıkları (KHD) ve ETS işaretlerinin otomatik olarak türetildiği aşamadır. Bu işlem her EKG kaydına dakika dakika uygulanmıştır. Özellik çıkarım aşaması ise bu iki işaretin (KHD ve ETS) FD tabanlı güç spektral yoğunluk kestirim bilgileri ve yine bu iki işaretin bazı istatistiksel hesaplama bilgilerinin (ortalama, standart sapma, vs) elde edildiği aşamadır. Sınıflandırma aşaması ise özellik çıkarım aşamasında elde edilen bilgilerin lineer discriminant (LD) ve quadratic discriminant (QD) sınıflandırıcılar yardımıyla analiz edilerek sınıflandırıldığı aşamadır. Sistemin test ver kümesi (her biri 1 dakika süreli olan 17268 EKG bölüt) üzerindeki başarı performans (doğruluk) %90 civarındadır [41].

De Chazal vd. (2004), bir başka çalışmada aynı sistemi farklı zaman ölçekli EKG işaretlerine uygulamışlar ve bu uygulama sonucunda sistemin kısa süreli EKG işaretler için OUAS'ı tespit etmedeki başarı performansının düştüğünü ifade etmişlerdir [42].

Mendez vd. (2009), De Chazal vd. tarafından OUAS'ın tespitine yönelik olarak geliştirilen algoritmanın bazı zayıf taraflarının bulunduğunu belirtmişlerdir. Algoritmanın en zayıf tarafının, KHD ve ETS işaretlerinden elde edilen özellik uzayının (88 farklı özellik) yüksek boyutlu olmasından kaynaklandığını ileri sürmüşlerdir. Diğer bir zayıf yönünün ise özellik çıkarma aşamasında kullanılan FD ile kısa süreli işaretler için yeterli frekans çözünürlüğü sağlanamayacağını ifade etmişlerdir. Mendez vd., de Chazal vd. tarafından geliştirilen algoritmanın bu zayıf taraflarının üstesinden gelebileceğini idea ettikleri farklı bir yaklaşım önermişlerdir. Bu yaklaşımda, KHD ve ETS işaretlerinin spektral analizi için AR modelini ve bu analiz sonucu elde edilen yüksek boyutlu özellik uzayının boyutunu düşürmek için ise bir özellik seçme yöntemi olan ileri yönlü özellik seçme algoritmasını kullanılmıştır. Sınıflandırma sürecinde ise K-en yakın komşuluk ve YSA sınıflandırıcıları kullanmıştır. Önerilen yaklaşımın test veri kümesi üzerindeki en iyi başarı performans %88 olmuştur [43].

Mendez vd. (2010), EKG kayıtlarından OUAS'ın tespiti için yapmış oldukları bir başka çalışmada ise KHD ve ETS işaretlerinin analizi için iki farklı yöntem daha kullanmışlardır. Bu yöntemlerden biri ampirik mod ayrışımı ("empirical mode

decomposition”) diğeri ise DD’dir. İşaretlerin her iki yöntemle göre ayrı ayrı analizi sonucunda, DD’nin diğere yöntemle göre OUAS’ı tespit etmede daha etkin bir araç olduğı ifade edilmiştir. Her iki yöntemin test veri kümesi üzerinde OUAS’ı tespit etmedeki etkinliğinin QD sınıflandırıcı kullanılarak test edilmesi sonucu; DD ile %89, ampirik mod ayrışımı ile %85 oranında başarı sağlandığı bildirilmiştir [44].

Babaeizadeh vd. (2010), EKG’den türetilen KHD işaretlerini kullanarak OUAS’ın otomatik tespitini yapan çalışmalarında, daha önceki çalışmaların KHD işaretlerinin güç spektral yoğunluk kestirimi için kullanımını önerdikleri FD [41, 42] ve AR modeli [43] yerine, yine bir güç spektral yoğunluk kestirim yöntemi olan Lomb algoritmasını kullanmışlardır [45]. Bu algoritma ile KHD işaretinin elde edilen güç spektrumu belirli birkaç banda ayrıştırılmış ve ardından her bandın altındaki alan hesaplanarak işaretin özellikleri elde edilmiştir. KHD’nin bu şekildeki analizinin OUAS’ı tespit etmedeki etkinliğinin testi için ise bir kuadratik sınıflandırıcı kullanılmıştır. Sınıflandırıcının test veri kümesi (her biri 1 dakika süreli olan 17268 EKG bölüt) üzerindeki başarı performans %85 civarında olmuştur.

Lweesy vd. (2009), kısa süreli EKG işaretlerin OUAS’lı olup olmadığının kestirimi için diğere çalışmalardan farklı olarak EKG’nin P dalgasındaki şekil ve zaman değişimlerinin kullanıldığı bir çalışma yapmışlardır. Bu çalışmada P dalgasının genliği, süresi ve bu dalganın R dalgasına olan uzaklığı (PR) kısa süreli EKG işaretini karakterize eden özellikler olarak belirlenmiştir. Belirlenen bu özellikler bir YSA girişine verilerek (eğitim ve test süreci) EKG işaretinin OUAS barındırıp barındırmadığına bakılmıştır [46]. EKG’nin P dalgasındaki şekilsel değişimlerin OUAS’ın değerlendirilmesinde kullanılabileceğini öneren bir çalışma daha önceleri yapılmıştır [47]. Ayrıca EKG’nin diğere bir dalgası olan T dalgasına ait şekilsel değişimlerin de OUAS’ın değerlendirilmesinde kullanılabileceğini gösteren çalışmalar da literatürde mevcuttur [39, 48].

Şimdiye kadar özetlenen çalışmalarda kullanılan algoritmalar, EKG kayıtlarının dakika dakika analiz edilerek bu analiz sonucunda belirlenen bir eşik değerine göre EKG kayıtlarının OUAS hastası sınıfına ait olup olmadığı kararına yönelik geliştirilmiştir. Literatürdeki bazı çalışmalarda ise tüm EKG kaydını analiz ederek bu analiz üzerinden EKG kayıtlarının OUAS hastası sınıfa ait olup olmadığına karar veren algoritmalar geliştirilmiştir. Bu çalışmalardan bazıları aşağıda özetlenmiştir.

Hossen vd. (2005), kişinin tüm EKG kaydını kullanarak kişinin OUAS hastası sınıfa ait olup olmadığının tespitine yönelik geliştirdiği algorithmada, öncelikle bir ön işlem aşaması ile EKG kayıtlarından KHD işaretleri türetilmiştir. Daha sonra bir tür filtre bankası kullanılarak bu işaretlerin bazı özellikleri çıkarılmıştır. Daha sonra da elde edilen bu özelliklerin her birine ROC analiz yöntemi uygulanarak bazı karar mekanizmaları (sınıflandırıcılar) oluşturulmuştur. Geliştirilen algoritmanın test için ayrılan EKG kayıtlarına uygulanmasındaki en iyi başarımlı performans %93.3 olmuştur [49].

Khandoker vd. (2009a) ise tüm EKG kaydını kullanarak kişinin OUAS hastası sınıfa ait olup olmadığının tespiti için DD analizi ve DVM sınıflandırıcısına dayalı otomatik bir sistem geliştirmiştir. Geliştirilen sistemin test veri kümesi üzerindeki başarımlı performansının %100 olduğu ifade edilmiştir [50]. Khandoker vd., (2009b) bir başka çalışmada aynı sistemi farklı bir EKG veri bankasına uygulamışlardır. Sistemin bu veri üzerindeki test başarımlı performansını ise %93 civarında olmuştur [51].

EKG kayıtlarının dışında, oksijen saturasyonu [52-54], solunum [55, 56] ve EEG [57] gibi farklı türde fizyolojik işaretler kullanıp OUAS'ın tespitini yapan çalışmalarda literatürde mevcuttur. Yapılmış olan bu tür çalışmalar, mevcut tez çalışmasının kapsamı dışında kaldığı için detayları verilmemiştir.

1.2. Tez Çalışmasının Amacı ve İzlenen Yöntem

Bu tezde iki temel amaç güdülmüştür. Bunlardan birincisi uyanık durumdan uyku durumuna geçiş sürecinde kaydedilen EEG işaretlerinden kişinin uyanıklık seviyesini uyanık, uyuklama ve uyku olarak tespit eden otomatik bir örüntü tanıma sistemi sunmaktır. Sunulan bu sistemde EEG işaret örüntülerinin karakteristik özelliklerinin ortaya çıkarılması için DD tabanlı iki ayrı özellik çıkarım yöntemi kullanılmıştır. Bu özellik çıkarım yöntemlerinin her birinin etkinliği üç farklı yapay zeka tekniği olan YSA, En Küçük Kareler Destek Vektör Makineleri (EKK-DVM) ve ANFİS sınıflandırıcıları üzerinde test edilerek uyanıklık seviyesinin tespiti için 6 farklı sınıflandırma yaklaşımının performansının karşılaştırılması yapılmıştır. Ayrıca sunulan sistem performans açısından literatürdeki benzer çalışmalar [19, 28, 29, 31, 32] ile kıyaslanmıştır.

Bu tezin ikinci temel amacı ise kişinin tüm EKG kaydından OUAS hastası olup olmadığını belirleyen bir otomatik örüntü tanıma sistemi sunmaktır. Bu sistemde öncelikle DD analizine dayalı bir algoritma kullanılarak EKG kaydından KHD ve ETS işaretleri

hesaplanmıştır. Daha sonra gerek KHD ve gerekse ETS işaretlerinin karakteristik özelliklerinin ortaya çıkarılması için yine DD tabanlı iki ayrı özellik çıkarım yöntemi kullanılmıştır. Sistemin son kısmını oluşturan sınıflandırma kısmında ise YSA, diğeri ise EKK-DVM olmak üzere iki farklı sınıflandırıcı kullanılmıştır. Bu otomatik örüntü tanıma sistem ile EKG kayıtlarından kişinin OUAS hastası olup olmadığının tespiti için 12 farklı sınıflandırma yaklaşımı yapıp her sınıflandırma yaklaşımı performans açısından karşılaştırılmıştır. Yine bu tez de sunulan sistem, performans açısından literatürdeki benzer çalışmalar ile kıyaslanmıştır [49-51].

Tez çalışmasında kullanılan ve geliştirilen tüm algoritmalar için MATLAB paket programından yararlanılmıştır.

1.3. Tez Çalışmasının İçeriği

Bu tez çalışması, yukarıda belirtilen amaca uygun olarak altı bölümden oluşmaktadır. **Bölüm 2**'de EEG işareti ve bu işaretin ölçüm yöntemleri hakkında temel bilgiler verilmiştir. Yine bu bölümde uyku, uyku evreleri ve uyanıklık seviyesine ilişkin temel kavramlar tanıtılmıştır. **Bölüm 3**'de öncelikle EKG işareti ve bu işaretin ölçüm yöntemleri tanıtılmış, daha sonra OUAS hastalığı ve bu hastalığın tanısında kullanılan PSG çalışma tekniğine ilişkin temel bilgiler verilmiş ve son olarak da EKG ve OUAS hastalığı arasındaki ilişki üzerinde durulmuştur. **Bölüm 4**'de öncelikle bu çalışmada sunulan örüntü tanıma sistemlerini anlaşılabilir kılmak için genel bir örüntü tanıma sistemi ve bu sistemi oluşturan temel bileşenler (süreçler) tanıtılmıştır. Daha sonra EEG ve EKG için sunulan örüntü tanıma sistemlerinin özellik çıkarım süreçlerinde kullanılan DD, Welch güç spektral yoğunluk kestirimi ve entropi hesaplama tekniğine ilişkin teorik bilgiler verilmiştir. Yine bu bölümde sunulan örüntü tanıma sistemlerinin sınıflandırma sürecinde kullanılan yapay zeka tekniğine dayalı sınıflandırıcılar (YSA, EKK-DVM ve ANFIS) tanıtılmıştır. **Bölüm 5**'de bölüm 4'de tanıtımı yapılan tekniklere dayalı olarak geliştirilen örüntü tanıma sistemleri ve uygulamaları birlikte verilmiştir. **Bölüm 6**'da ise uygulama sonuçları irdelenmiş ve literatürdeki benzer çalışmalarla kıyaslanmıştır.

2. EEG ve UYKU

Bu tez çalışmasının iki temel amacından biri EEG biyolojik işaretinden uyanıklık seviyesinin tespit eden otomatik bir sistem sunmaktır. Bu bölümde EEG işareti ve uyku fizyolojisi ile ilgili temel bilgiler verilecektir.

2.1. EEG

İnsan vücudunda, hücrelerde oluşan biyolojik kaynaklı elektriksel aktivitenin sonucu olarak, pek çok elektriksel işaret oluşmaktadır. Bu işaretlerden birisi, beyinde var olan sinir hücre gruplarının elektriksel aktivitesinin grafiksel gösterimi olan EEG dalgalarıdır [58]. EEG, Grekçe kelimelerden oluşup, “Beyin elektriksel resmi” anlamına gelmektedir [59]. EEG kayıtları kafatasına yerleştirilen elektrotlar ile ölçülür.

EEG’nin tarihsel gelişimi, **Caton’un (1875)** hayvanlar üzerinde yaptığı deneyler sonucunda beyinde bir takım elektriksel faaliyetlerin var olduğunu bulmasıyla başlamıştır [60]. İlk defa insan beynindeki elektriksel aktivitenin varlığını ise, kafatası yüzeyine yerleştirilen elektrotlar ve bunlara bağlı galvanometre yardımıyla ortaya koyan Hans Berger’ dir [58]. Berger (1929), EEG dalgaları adı verilen beynin elektriksel aktivitesinin gözün açılıp kapanmasıyla değiştiğini göstermiştir. Ancak, bilim çevrelerince, kaydedilen bu dalgaların insan beyninden değil, kullanılan cihazlardan kaynaklandığı ileri sürülmüştür. EEG işaretlerinin varlığının bilimsel şekilde kesin olarak ortaya konması, elektronikteki gelişmeler ile birlikte **Adrian ve Matthews’un (1934)** elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydetmeleriyle olmuştur [61]. Elektronik ve bilgisayar teknolojisinin sağladığı avantajlarla yapılan çalışmalar sonucunda, EEG dalgalarının beyin fonksiyonlarını anlamak için en önemli işaretlerden biri olduğu görülmüştür [60]. EEG işaretlerinin, yaşa [62], cinsiyete [63, 64], beynin uyanıklık durumuna [11, 58, 65], bilişsel uyaranlara [58] ve beyin hastalıklarının var olup olmamasına [66, 67] bağlı olarak değişimler gösterdiği saptanmıştır.


EEG günümüzde, sinir sistemi çalışmalarında, uyku analizlerinde, epilepsi gibi rahatsızlıkların izlenmesinde ve odak tespitinde, beyin hasarlarının yerinin tespitinde ve

duyusal merkezlerdeki bozuklukların tespiti gibi birçok alanda yaygın olarak kullanılmaktadır.

2.1.1. EEG Dalgaları


Kafatasına yerleştirilen elektrotlar yardımıyla alınan EEG işaretleri, genliği $10 \mu V$ ile $200 \mu V$ aralığında ve frekansı $0,5 \text{ Hz}$ ile 100 Hz aralığında olan, durağan olmayan dinamik işaretlerdir [58]. Beyin aktivite düzeyindeki değişime göre EEG içerisinde belirli frekans aralığındaki dalgalar baskın özellik gösterir. EEG kullanılarak patolojik veya fizyolojik bir durum ile ilgili bir değerlendirme, EEG işareti içerisinde bulunan bu baskın frekans aralığındaki dalgalara göre yapılır. EEG işaretini oluşturan ve özel adlarla anılan bu dalgalar aşağıda verildiği şekilde tarif edilmiştir [60, 68, 69] ;

- **Delta dalgası:** Frekans aralığı $0.5 - 4 \text{ Hz}$ olan delta, genliği en yüksek ve frekansı en düşük dalgalardır [68]. Bu dalgalar uyku esnasında yetişkinlerde ve bebeklerde sıklıkla görülür [69]. Şekil 2.1’de 1 saniyelik örnek bir Delta dalgası verilmiştir.




Şekil 2.1. Delta dalgası [69].

- **Teta dalgası:** ‘Teta’ terimi ilk defa Walter ve Doney (1944) tarafından kullanılmıştır [60]. Frekans aralığı $4-8 \text{ Hz}$ olan teta dalgaları, uykulu haldeki çocuklarda ve yetişkinlerde görülür [68, 69]. Şekil 2.2’de 1 saniyelik örnek bir teta dalgası verilmiştir.




Şekil 2.2. Teta dalgası [69].

- **Alfa dalgası:** İlk defa **Berger (1929)** tarafından adlandırılan Alfa dalgası, 8-13 Hz frekans aralığına sahip olan dalgalarlardır [68]. Uyanık bireylerin fiziksel ve zihinsel olarak dinlendiği ve gözlerinin kapalı olduğu durumda daha fazla görülürler [69]. Şekil 2.3’de 1 saniyelik örnek bir alfa dalgası verilmiştir.




Şekil 2.3. Alfa dalgası [69].

- **Beta dalgası:** Frekans aralığı 13-30 Hz ve genlik olarak alfa dalgalarından daha küçük olan dalgalarlardır [68]. Beta, beynin fiziksel ve bilişsel aktivitelerin yoğun olduğu durumlarda görülür [69]. Şekil 2.4’de 1 saniyelik örnek bir Beta dalgası verilmiştir.



Şekil 2.4. Beta dalgası [69].

- **Gama dalgası:** Frekans aralığı yaklaşık olarak 30-100 Hz olan dalgalarlardır [68, 69]. Şekil 2.5’de 1 saniyelik örnek bir gama dalgası verilmiştir.




Şekil 2.5. Gama dalgası [69].

2.1.2. EEG İşaretlerinin Ölçülmesi


Bilgisayarların gelişimi ile birlikte EEG kaydı almak, alınan kayıtları analiz etmek ve çıkan sonuçları saklamak daha kolay hale geldi. Günümüzde Şekil 2.6'de görüldüğü gibi beyin ile bilgisayar arasında kurulan bir sistem ile kayıt ve analiz işlemlerini daha kolay bir şekilde yapabilmekteyiz. Bu sistem aşağıda tanımlanan 4 temel birimden oluşur.

- Kafatası elektrotları: Kafatası yüzeyindeki elektriksel potansiyelleri ölçmek için kullanılırlar (şekil 2.6a).
- Dönüşüm Kuvvetlendiricisi: Elektrotlar aracılığı ile elde edilen EEG sinyallerinin analog olarak filtrelenmesi ve örneklenmesi görevini görür (Şekil 2.6b).
- İşlemci arabirimi: Dönüştürücü çıkışından elde edilen analog EEG işaretlerinin sayısal olarak işlenmesi ve bilgisayar seri portlarında algılanabilecek hale dönüştürür (Şekil 2.6c).
- Kişisel Bilgisayar: İşlemci arabiriminden gelen işaretlerin saklanması ve ekranda görüntülenmesini sağlar (Şekil 2.6d).



Şekil 2.6. Beyin-bilgisayar arabirimi [60].

EEG işaretlerinin ölçülmesinde kullanılan sistemin ilk kısmını oluşturan metal elektrotların kafatasına yerleşiminde uluslararası standartlar kullanılır. En çok kullanılanı 10–20 EEG elektrot yerleştirme sistemidir (Şekil 2.7). Bu yerleştirme sistemine göre baş dört standart noktayla işaretlenmiştir. Bu noktalar burun (nasion), başın arka kısmı (inion), sol ve sağ kulak arkalarıdır (preauriculars). Elektrotlar burun ve başın arka kısmı arasında %10–20–20–20–10 olacak şekilde bölünerek yerleştirilir. Diğer elektrotlar, bu elektrotlarla birlikte bir daire oluşturacak şekilde yerleştirilirler. Böylece 19 elektrot kafa üzerine yerleştirilmiş olur. Kulak memesine yerleştirilen 20. elektrot ise toprak elektrotu olarak kullanılır [70].



Şekil 2.7. Uluslararası 10–20 EEG elektrot yerleştirme sistemi [70].

2.2. Uyku

“Uyku; karmaşık, yüksek derecede organizasyon gösteren, birçok iç ve dış faktörden etkilenen, belli dönemlerinde beyinin uyanıklık kadar aktif olduğu, geri dönüşümlü bir bilinçsizlik ve seçici yanıtsızlık özellikleri gösteren bir süreçtir” [71]. Uyku, tüm vücudu ilgilendiren etkileri olsa da gerçekte beyin bir işlevidir.


İnsan yaşamının 1/3’ünü oluşturan uyku, yıllarca, uyanık durumun ortadan kalkmasıyla oluşan pasif bir durum olarak düşünülmüştür. Bu düşünceye göre uyku, beyin uyarıcı alanlarını barındıran beyin sapı ve diğer parçaların yorularak işlevsiz kalmasının sonucunda oluşan bir durumdur. Uyku hakkındaki bu görüş yirminci asrın ortalarına kadar geçerliğini korumuştur. Ancak teknolojik gelişmelerin getirdiği avantaj ile uyku ve uyanık durumda iken beyin dinamiği üzerinde yapılan çalışmalar, uykunun aslında merkezi sinir sisteminin aktif katılımıyla ortaya çıktığını göstermiştir [12].

Uyku konusunda çalışmalar, EEG’nin gelişmesi ve beyin araştırmaları üzerinde kullanılmasıyla büyük bir hız kazanmıştır. EEG’nin mucidi olan ve bunu uyku çalışmalarında ilk kullanan Berger (1929), EEG örüntüsünün uyku ve uyanık durumda farklılık gösterdiğini gözlemlemiştir. Bu çalışmadan birkaç yıl sonra Loomis vd., (1937), beyin EEG örüntüsüne göre uykunun birkaç evreden oluştuğunu belirlediler. 1953 yılında uykuda periyodik olarak ortaya çıkan hızlı göz hareketleri (Rapid Eye Movement) (REM) uykusunun keşfi ile Dement ve Kleitman (1957) tarafından uykunun aslında REM

ve non-REM (NREM) uykusu olarak iki temel evreden oluştuğunu ve NREM uykusunun da kendi içinde 4 alt uyku evresinden oluştuğunu gösterdiler [12, 61, 72].

Giderek belirli bir disiplin içinde toplanmaya başlayan uyku çalışmaları, standartları belirlenerek bilimsel çalışma yapılması için ortak tanımlara ve ölçütlere ihtiyaç duymuştur. Rechtschaffen ve Kales (1968) uyku çalışmalarında standart ölçütler olarak kabul edilen uyku evrelerini belirlemeye yönelik bir çalışma hazırlamışlardır. Bu çalışmaya göre sağlıklı bir kişide uyku Evre I, Evre II, Evre III, Evre IV ve REM olmak üzere 5 evreden oluşmaktaydı. 2007 yılına kadar uyku evrelerinin belirlenmesi bu çalışmanın belirlediği prensipler esas alınarak yapılmaktaydı. 2004 yılında Amerikan Uyku Tıbbı Akademisi'nin (American Academy of Sleep Medicine) oluşturduğu bir çalışma grubu, uyku ve uykuyla ilişkili olaylar konusunda yeni prensipler belirlemiş ve 2007 yılında yayınlamıştır [73].

Günümüzde uyku, uyku çalışması olarak da adlandırılan polysomnografi adı verilen yöntemle incelenmektedir [8]. Bu yöntem ile insan beyin aktivitesi (EEG), kas aktivitesi (EMG), göz hareketleri (EOG), kalp aktivitesi (ECG), üst-alt solunum yolu aktivitesi, karın-göğüs solunum çabası ve oksijen saturasyonu gibi işaretler PSG adı verilen cihaz ile kaydedilir. Kaydedilen bu biyolojik işaretler uzman kişilerce değerlendirilerek uyku fizyolojisi veya uyku hastalıkları incelenir. Uyku evrelerinin belirlenmesi çalışmalarında EEG, EOG ve EMG kayıtları değerlendirilmesi zorunlu olun biyolojik işaretlerdir. Şekil 1'de EEG (C4-A1 kanalına ait), EOG (sağ ve sol göze ait) ve EMG (çeneye ait) kayıt şekli verilmiştir.



Şekil 2.8 Polisomnografide EEG, EOG ve EMG kaydı.

2.2.1 Uyku Evreleri

Amerikan Uyku Tıbbı Akademisi'nin belirlediği prensiplere göre uyku, uyanık evre, NREM evre I-II-III ve REM olmak üzere beş evreden oluşmaktadır [73]. Bu prensipler kapsamında evrelerin temel karakteristik özellikleri aşağıda verildiği gibidir:


- **Uyanık evre:** Bu evre, kişinin en uyanık bulunduğu durumdan, uykuyu dalmak üzere olduğu duruma kadar değişen bir yelpazeyi içerir. Alfa aktivitesi ve /veya düşük genlikli, karışık frekanslı EEG ile karakterizedir. Ayrıca, EMG'de yüksek karışık tonik aktivite ve EOG'de hızlı göz hareketleri (göz kırpmaları) vardır. Uykuya dalmak üzereyken göz kırpmaların sıklığı azalarak yerini yavaş göz hareketlerine bırakır. Ayrıca, Alfa aktivitesinde de azalmalar görülür.
- **NREM Evre I:** Uykunun başlangıç evresidir. Bu evrede 8-13 Hz'lik Alfa dalgaları yok olarak yerini 4-7 Hz'lik teta dalgalarına bırakmaktadır. EOG'de yavaş göz hareketleri görülür. EMG'de ise uyanıklık evresine göre azalmış aktivite gözlenir. Bu evrede kişi rahat uyandırılır. Bu sebeple hafif uyku olarak da bilinir. NREM Evre I tüm uyku süresinin %2-5'ini kapsar.
- **NREM Evre II:** Bu evre, EEG kayıtlarında görülen 12-14 Hz'lik uyku içcikleri ve K kompleksi ile karakterizedir. EOG'de genellikle göz hareketleri görülmez. EMG aktivitesi azalmaya devam eder. Bu evre tüm uykunun %45-55'lik kısmını kapsar.
- **NREM Evre III:** Uykunun en derin evresidir. EEG'nin 0.5-2 Hz'lik yavaş Delta dalgasıyla karakterizedir. EOG'de göz hareketleri izlenmez. EMG 'de görülen kas aktivitesi NREM evre III'dekine göre daha düşüktür. NREM evre III tüm gece uykusunun %20-25 ini içerir. Bu evrede kişiyi uyandırmak zordur.
- **REM evresi:** Bu evre, EEG kayıtları açısından NREM I evresi ile benzerlik gösterir. Evrenin en karakteristik özelliği EOG kayıtlarında gözlenen hızlı göz hareketleri olmakla birlikte diğer bir önemli karakteristik özelliği uyku evreleri içinde çene EMG kayıtlarının en düşük aktivite göstermesidir. Uykunun REM evresi kişiye ait tüm uyku süresinin %20-25'ini kapsar. Rüyaların %80'ni bu evrede görülür.

NREM evre I başlayan ve REM evresi ile sonuçlanan uyku süresi, uykunun bir periyodunu oluşturur. Uykunun bir periyodu 80 il 100 dakika arasında değişebilmektedir. Bir gece uykusu bu periyotların peş peşe 4-6 kez tekrarlanmasından meydana gelir.

2.2.2. Uyanıklık Seviyesi

Literatürde “vigilance level” olarak adlandırılan uyanıklık seviyesi, genelde beyin dinamiğinin aktivite düzeyini tanımlamak için kullanılan bir ifadedir [11, 19]. Uyanıklık seviyesinde temel olarak üç farklı fizyolojik durum söz konusudur [19, 28, 29, 31, 32]. Bunlar uyanık (alert), uyuklama (drowsy) ve uyku (sleep) durumlarıdır (Şekil 2.9). Uyanık durum, kişinin aktif veya dinlenme sürecindeki fizyolojik durumudur. Uyku durumu ise kişinin N-REM I uyku evresiyle başlayıp REM uyku evresiyle sonlanan uzun süreli fizyolojik durumudur. Uyuklama ise dinlenmiş haldeki uyanık durumundan, uykunun ilk evresi olan N-REM evre I'e geçişte yaşanan kısa süreli fizyolojik durumdur. Bu çalışmada uyanıklık seviyesinin 3 farklı durumundan biri olan uyku durumu, N-REM I evresi ile sınırlandırılmıştır. Bu bağlamda beynin elektriksel aktivitesi olan EEG işaretine göre uyanıklık seviyesinin 3 farklı fizyolojik durumu aşağıda verildiği gibi karakterize edilir [11]:

- **Uyanık durum:** Kişi gözlerinin açık olduğu aktif uyanık durum, EEG işaretinin düşük genlikli beta aktivitesi ile karakterizedir. Gözlerin kapalı olduğu ve dinlenme halindeki kişinin uyanık durumu ise EEG işaretinin Alfa aktivitesi ile karakterizedir.
- **Uyuklama durumu:** Uykuya geçişin hazırlık aşaması olan uyuklama sürecinde EEG işaretinin Alfa ve Beta dalgaları tedricen azalarak yerini Teta dalgalarına bırakır.
- **Uyku durumu (NREM evre I):** EEG işaretinin Teta aktivitesinin baskın olduğu ve Alfa aktivitesinin büyük oranda azaldığı süreçtir.



Şekil 2.9. Uyanıklık seviyesinin 3 farklı durumunu tanımlayan gösterim.

3. EKG ve OBSTRUKTİF UYKU APNE SENDROMU

Bu tez çalışmasının amaçlarından biri de EKG biyolojik işaret kayıtlarını kullanarak OUAS'ı tespit eden otomatik bir sistem sunmaktır. Bu bölümde EKG işareti ve OUAS'a ilişkin temel bilgiler verilecektir.

3.1. EKG


Kalp kasının ve sinirsel iletim sisteminin çalışmasını incelemek için kalpte meydana gelen elektriksel faaliyetin, vücut yüzeyinden kaydedilmesine Elektrokardiyografi denir. Bu kayıt ile elde edilen işaretlere Elektrokardiyogram (EKG), kayıt için kullanılan cihaza da Elektrokardiyograf denir. EKG, vücutta standart olarak belirlenmiş yerlerden elektrot sistemi aracılığıyla kaydedilir. Elde edilen bu kayıtlar kağıda çizdirilebileceği gibi bilgisayar ortamına da aktararak görüntülenebilmektedir. Tipik bir EKG işaretinin genliği ± 2 mV dolaylarındadır ve kayıt için 0,05 ile 150 Hz arasında bir bant genişliğine ihtiyaç duyulur.

İnsan kalbine ait ilk EKG kayıt sistemi, 1887 yılında A. D. Waller tarafından önerilmiştir. Önerilen bu kayıt sistemi, hantallığı ve barındırdığı bazı kısıtlamalar nedeniyle klinik çalışmalarda pek kullanılmamıştır. Gerçek manada klinik çalışmalarda kullanılan ilk EKG kayıt sistemi, 1901 yılında Williem Einthoven tarafından önerilmiştir. Einthoven geliştirdiği kayıt sistemi ile hastalıklı ve sağlıklı kişilerden elde ettiği EKG işaretlerinin birbirinden farklı olduğunu göstermiştir. Günümüzde kullanılan gelişmiş EKG kayıt sistemleri Einthoven tarafından bulunan bu sistemin temelleri üzerine kuruludur [74].

EKG işareti 3 temel bileşenden oluşmaktadır. Bu temel bileşenleri tanımlayan P, QRS ve T dalgaları Şekil 3.1.'de verilmiştir. Bu şekilden görüldüğü gibi, bu dalgaların oluşum sırası önce P, ardından QRS kompleksi ve son olarak T şeklindedir. Bu dalgaların genlikleri, dalga genişlikleri ve dalgaların aralıkları değerlendirilerek EKG bir klinik tanı aracı olarak kullanılmaktadır. EKG'nin tanıda yardımcı olduğu belli başlı hastalıklar;

- Ritim Bozukluğu
- Uyarı merkezi ve ileti ile ilgili aksaklıkların belirlenmesi
- Myokard hastalıkları ve yerinin belirlenmesi

- Kalp hipertrofileri ve kalbin pozisyonunun belirlenmesi
 - Koroner damarlara ve kalp kapaklarına ilişkin hastalıkların saptanması
- olarak sıralanabilir.



Şekil 3.1 Normal EKG işareti.

3.1.1. EKG Dalgaları ve Aralıkları

Normal bir EKG işaretinde P, QRS ve T olarak adlandırılan karakteristik dalgalar kalbin özel iletim sisteminde uyarının yayılma evrelerine karşılık gelmektedirler. Bu dalgaların genlikleri, süreleri, dalgalar arasındaki zaman aralıkları (PR, QT, RR) tanısal bilgiler taşırlar. Normal bir EKG işareti için bu dalgaların ve dalgalar arasındaki aralıkların oluşum şekli ve temel karakteristikleri aşağıda verildiği gibidir;

- **P dalgası:** SA düğümünden çıkan ve atriumlara yayılan aksiyon potansiyeli atriyumların kasılmasına (depolarizasyon) sebep olur ve bunun sonucunda P dalgası ortaya çıkar. Bu dalganın genliği düşüktür ($50\text{--}100\ \mu\text{V}$), ortalama 100 ms uzunluğundadır ve frekans spektrumu 0.5-10 Hz aralığındadır.
- **PR aralığı:** P dalgasının başlangıcından Q dalgasına kadar olan aralık PR aralığı olarak tanımlanır ve atriyumlardan ventriküllere doğru olan iletimin süresini gösterir. PR aralığının normal değeri 120 ms ile 200 ms arasında değişmektedir.
- **QRS kompleksi (dalgası):** QRS kompleksi ventriküler kasılma ve depolarizasyon periyodunun sonucu olarak ortaya çıkan bir yapıdır. Atriyumların repolarizasyonu çok daha büyük genlikli bir sinyal üreten ventriküller tarafından bastırılır. QRS

kompleksinin, P dalgasından çok daha büyük bir sinyal olmasının sebebi, ventrikülleri oluşturan dokunun daha hacimli olmasından kaynaklanır. QRS kompleksi, Q dalgasından başlar ve S dalgasının taban çizgisine kavuştuğu noktada sonlanır. QRS kompleksleri genellikle en büyük genliğe ve en yüksek frekansa sahip EKG bileşenidir. Normal süresi 60 ms ile 100 ms arasında değişmektedir ve frekans spektrumu 10-25 Hz aralığındadır.

- **T dalgası:** T dalgası ventriküllerin repolarizasyonun sonucu ortaya çıkar ve QRS komplekslerinden süre olarak daha uzundur. Bunun sebebi ventriküllerin repolarize olmasının depolarize olmasından daha uzun sürmesidir. Normalde 0,5 mV civarında pozitif bir tepeye sahiptir. Negatif bir tepeye sahip olması da mümkündür. Bazen de çok düşük genliğe sahip olduğu için tespit etmesi oldukça zordur. Süresi normal şartlarda 200 ms veya daha azdır. Frekans spektrumu 0.5-10 Hz aralığındadır
- **QT aralığı:** QT aralığı Q dalgası ile başlar ve T dalgasının sonuna kadar sürer . Bu aralık, ventriküllerin kalbin bir atışındaki toplam depolarizasyon ve repolarizasyon süresini verir. Normalde 380 ms kadar sürmesi gerekmektedir birlikte kadınlarda, erkeklerde ve yaş ile bağlantılı olarak uzaması ya da kısalması mümkündür. Fizyolojik olarak her hangi bir sorun bulunmadığı takdirde, QT aralığının içinde bulunduğu RR aralığının toplam uzunluğunun %40'ı uzunlukta olması gerekmektedir.
- **R-R aralığı:** Bu aralık iki kalp atımı arasında geçen süreyi verir. Başka bir deyişle ardışık iki QRS kompleksi arasındaki mesafeyi ifade eder. Kalpteki olayların bir devri R-R aralığı ile belirlenir. Bununla birlikte süreklilik gösteren uzun süreli EKG kayıtları için bulunan R-R aralıkları değişkenliği ise kalp hızı değişkenliği (KHD) olarak ifade edilir [75].

3.1.2 EKG Ölçüm Yöntemleri

Standard EKG ölçümleri 12 ayrı elektrot grubu kullanılarak yapılır. Bu elektrot gruplarına derivasyon adı verilir. Her bir derivasyon kalbin elektriksel aktivitesine farklı bir açıdan bakmamızı sağlar. EKG derivasyonları üç kategoride incelenir [76]:

- Çift kutuplu ekstremite derivasyonları (I, II, III)

- Tek kutuplu ekstremite derivasyonlar (avR, avL, avF)
- Tek kutuplu göğüs derivasyonları (V1-V6)

Tek ve çift ekstremite derivasyonlar (I, II, III, avR, avL ve avF) her biri kalbi frontal düzlemde farklı açılardan gören eksenlere sahiptir. Ekstremitte derivasyonlarındaki dalga büyüklükleri (voltajları) değerlendirilerek kalpteki depolarizasyon (veya repolarizasyon) dalgasının hareket yönünün hangi eksene yakın olduğu araştırılır. Göğüs derivasyonları (V1-V6) ise kalbin frontal kesitte değerlendirilmesini sağlarlar. Dolayısıyla, ekstremite ve göğüs derivasyonlarını bir arada kullanılmasıyla, kalbin elektriksel aktivitesi yatay ve dikey düzlemde değerlendirilmiş olur.

I, II, III derivasyonları kol ve bacaklara bağlanan biri artı diğeri eksi kutup olan iki elektrot kullanılarak kaydedilir. Kayıt için kullanılan elektrotların farklı polaritede olması dolayısıyla bunlara çift kutuplu derivasyonlar denir. Bu derivasyonların ölçümü için kullanılan elektrot yerleştirme biçimi Şekil 3.2a.'da verilmiştir. Şekil 3.2a'dan görüleceği gibi RA sağ kol, LA sol kol, LL sol bacak anlamına gelir. Buna göre I, II ve III derivasyonları için (3.1), (3.2) ve (3.3) eşitlikleri geçerlidir.

$$I = V_{LA} - V_{RA} \quad (3.1)$$

$$II = V_{LL} - V_{RA} \quad (3.2)$$

$$III = V_{LL} - V_{LA} \quad (3.3)$$


avR, avL, avF derivasyonları da I, II, III derivasyonları gibi kol ve bacaklardan ölçülen fakat tek kutuplu olan derivasyonlardır. Bunların tek kutuplu diye adlandırılmalarının sebebi ise kayıt esnasında kullanılan elektrotlardan biri Wilson merkezi terminal (CT) olarak adlandırılan referans bir noktaya bağlanmasıdır. avR, avL, avF derivasyonların ölçümü için elektrot yerleştirme biçimi Şekil 3.2b'deki gibidir. Bu derivasyonlar I, II, III derivasyonları kullanılarak hesaplanabilir. Bu hesaplama için

$$avR = (2V_{RA} - V_{LA} - V_{LL})/2 \quad (3.4)$$

$$avL = (2V_{LA} - V_{RA} - V_{LL})/2 \quad (3.5)$$

$$avF = (2V_{LL} - V_{RA} - V_{LA})/2 \quad (3.6)$$

eşitlikleri kullanılır. avR, avL, avF gibi diğer tek kutuplu derivasyonlar göğüs derivasyonlarıdır. Bu derivasyonların ölçümü için Şekil 3.2c’de gösterildiği gibi elektrotlardan biri standart olarak seçilen 6 noktadan birine dokundurulurken, nötr olarak adlandırılan diğer elektrot referans olarak adlandırılan Wilson merkezi terminaline (CT) bağlanır. Bu şekilde V1,...,V6 diye adlandırılan 6 adet göğüs derivasyonu elde edilir.



Şekil 3.2. EKG derivasyonlarının elektrot yerleşim biçimi: a) Çift kutuplu kol bacak derivasyonları, b) Tek kutuplu kol bacak derivasyonları, c) Tek kutuplu göğüs derivasyonları.

3.2. Obstruktif Uyku Apne Sendromu

Uyku esnasında meydana gelen solunum bozuklukları, Obstruktif Uyku Apne Sendromu (OUAS), santral uyku apne sendromu, obezite-hipoventilasyon sendromu, overlap sendromu, üst solunum yolu rezistansı sendromu olmak üzere beş ana başlık altında toplanabilir [2]. OUAS, bunlar içinde en sık görülen hastalıklardan biridir. Amerika Birleşik Devletlerinde OUAS'ın 30-70 yaş arası popülasyonda kadınlarda %2, erkeklerde ise %4 oranında görüldüğü bildirilmektedir [3]. Ülkemizde ise görülme sıklığının %0.9-1.9 olduğu bildirilmiştir [77]. OUAS'ın görülme sıklığı dünya ülkelerine göre farklı oranlarda olabilmektedir. Davies ve Stradling (1996) dünyanın değişik ülkelerinde OUAS ile ilgili yapılan 12 çalışmanın ortak sonuçlarını yayınlamışlardır [78]. Bu sonuçlara göre ise OUAS'ın görülme sıklığının %1-5 arasında değiştiği görülmüştür.

OUAS; uyku sırasında üst solunum yolunun sürekli olarak tekrarlayan tam (apne) veya kısmi (hipopne) tıkanmaları ile karakterize edilir [2]. Solunumun en az 10 saniye süre ile tamamen kesilmesi apne olarak tanımlanırken, solunumun en az 10 saniye süre ile %50 oranında azalması ise hipopne olarak tanımlanmıştır. Solunumda tekrarlayan bu tıkanmalara neden olan risk faktörleri genel olarak bilinmesine rağmen, fizyopatolojik mekanizmalar tam olarak anlaşılamamıştır.

OUAS için bilinen başlıca risk faktörleri obezite, geniş boyun çevresi, kraniyofasiyal anomaliler, hipotiroidizm ve akromegali'dir. Bu etkenler üst havayolu açıklığını farinks çevresindeki yağ dokuda artış (obezite) veya farinks içindeki dokuda artış (hipotiroidizmi akromegali) nedeniyle daraltmakta, uyku sırasında yineleyen solunum bozukluklarını kolaylaştırmaktadır [79].

OUAS'ın, horlama, tanıklı apne ve gündüz aşırı uyku hali olmak üzere üç ana klinik semptomu vardır [80]. Horlama, OUAS'lı hastaların yaklaşık %95 inde görülen bir semptomdur. Uyku sırasında orofarenkste inspirasyonun kısmi olarak engellenmesiyle oluşan kaba, gürültülü, vibratuar bir sestir. Sık tekrarlayan apneler nedeniyle gece boyunca düzensiz horlama, OUAS'lı hastalarda tipiktir.

Hastalar genellikle apnelerin farkında olmazlar. Ancak OUAS'lı hastaların eşleri veya yakınları, gürültülü ve düzensiz horlamanın aralıklarla kesildiğini, ağız ve burunda solunumun durduğunu, bu sırada göğüs ve karın hareketlerinin paradoks olarak devam ettiğini tanımlayabilirler. Buna tanıklı apne denmektedir. Bu tabloyu şiddetli bir horlama ile birlikte derin bir soluk alma takip eder, göğüs ve karın hareketleri eş zamanlı hale gelir

ve ağız/burun solunumu bir sonraki apneye kadar devam eder. Apne süresi genellikle 10-60 saniye arasındadır, nadiren iki dakikaya kadar uzayabilir. Daha uzun süreli apneler yaşamı tehdit edici olabilir.

Üçüncü ana semptom ise gündüz aşırı uyku halidir. Bu semptom uykuda sık tekrarlayan apneler sonucu gelişir. Uyku bölünmeleri nedeniyle OUAS'lı hastalar ertesi gün aşırı uyku ihtiyacı hisseder. OUAS dışında birçok akut ve kronik hastalık tablosunda da görülebilmesi nedeniyle düşük spesifiteye sahip bir semptom olmakla birlikte özellikle ağır dereceli OUAS'lı hastalar için önemli bir belirleyicidir. Gündüz aşırı uyku hali hafif-ağır dereceli olabilir ve ağırlığı apne periyodlarının sıklığı, süresi ve buna eşlik eden oksijen desatürasyonunun derecesi ile sıkı ilişkilidir. Gün içindeki uykuya meyil sebebiyle OUAS'lı hastaların fiziksel ve bilişsel performansında görülen düşüş ile birlikte bu hastaların birçok iş ve trafik kazalarına neden olduğu bildirilmiştir [4, 5, 81].

OUAS, kişinin günlük yaşam kalitesini düşürüp ölümle sonuçlanabilecek birçok işyeri ve trafik kazalarına neden olduğu gibi birçok hastalığın gelişmesinde de risk faktörü olarak düşünülmektedir. Özellikle kardiyovasküler sistemle ilgili bazı hastalıklar, uyku apne sendromunun sonuçları olarak değerlendirilmektedir. Bu sonuçlar içinde yüksek oranda morbidite ve mortaliteye (ölüm) neden olan hipertansiyon, koroner arter hastalığı, aritmiler, kalp yetmezliği ve serebrovasküler hastalık gibi kardiyovasküler hastalıklar bulunmaktadır [6, 7]. Bütün bu sonuçlar OUAS hastalığının erken tanı ve tedavisinin ne kadar önemli olduğunu göstermektedir.

Tüm solunum bozukluklarında olduğu gibi OUAS hastalığının kesin tanısı ancak polisomnografik inceleme tekniği ile koyulabilir. Bu yöntem bir sonraki alt başlık altında detaylı bir şekilde anlatılacaktır. OUAS tanısı konulmuş hastalar için en etkin tedavi yöntemi ise CPAP (Continuous positive airway pressure)'dir [82]. CPAP hastaya burundan sürekli pozitif basınçlı hava verilerek üst solunum yolu tıkanıklığının engellenmesi esasına dayanan tedavi şeklidir. Güncel çalışmalar CPAP kullanımının başta kardiyovasküler sonuçlar olmak üzere OUAS'ın tüm olumsuz etkilerini önlediğini göstermiştir [83].

3.2.1. Polisomnografi Tanı Tekniği

OUAS tanısı için “altın standart” tanı yöntemi PSG'dir [8, 9]. Uyku çalışma tekniği olarak da bilinen PSG; Uyku sırasında, nörofizyolojik, kardiorespiratuar, diğer fizyolojik ve fiziksel parametrelerin gece boyunca ve eş zamanlı olarak kaydedilmesi ve kaydedilen

bu parametrelerin incelenmesi tekniğine verilen genel bir isimdir [84]. Standart PSG sırasında rutin olarak kaydedilmesi gereken parametreler aşağıda verildiği gibidir;

- EEG
- EOG
- EMG - submentalis
- Ağız/burun hava akımı (solunumu)
- Göğüs/karın solunum hareketleri
- Oksijen saturasyonu
- EKG
- EMG - tibialis
- Vücut pozisyonu

Uyku ile ilgili tüm çalışmalarda EEG, EOG ve EMG-submentalis kayıtları esastır. Bu kayıtlar ile uyku evrelemesi (N-REM ve REM) yorumlanır. OUAS'lı olgularda derin uyku (NREM III) ve REM uykusu azalırken, yüzeysel uyku (NREM I-II) oranı ise artış gösterir.

Ağız/burun hava akımı ölçümü ve Göğüs/karın solunum hareketlerinin ölçümü ile apnenin varlığı, tipi (obstruktif, santral) ve apne süresi değerlendirilir. Apnenin obstruktif olarak adlandırılabilmesi için ağız/burun hava akımında görülen tam (apne) veya kısmi (hipopne) tıkanmalara göğüs/karın solunum hareketlerinin/çabasının da eşlik etmesi gerekir. Hava akımında görülen tıkanmalara rağmen solunum hareketleri/çabası yoksa bu tip apne ise santral apne olarak adlandırılır. PSG çalışma sonucu OUAS'ın gerek tanısı ve gerekse ağırlığının belirlenmesinde en çok kullanılan kıstas Apne Hipopne İndeksi(AHI) 'dir. AHI uyku süresince görülen toplam apne/hipopne sayısının toplam uyku süresine bölünmesiyle elde edilen değer olarak tarif edilir. AHI değerinin 5'den büyük olması OUAS tanısı koydurtur. OUAS açısından klinik olarak önemi olan olguların belirlenmesi ve bu konudaki çalışmalarda ortak bir dil kullanılabilmesi amacıyla, AHI dikkate alınarak yapılan sınıflandırma Tablo 1'de görülmektedir.

Kan oksijen saturasyonu ölçümüyle postapneik ve /veya non-apneik desaturasyon varlığı tesbit edilir. OUAS'da sık tekrarlayan oksijen desaturasyon periyotları görülür. EKG kaydı ile kardiyak patolojilerin varlığı belirlenir. Apne sırasında kalp hızı genelde yavaşlar, apne sonrası dönemde ise hızlanır. EMG (tibialis) kaydıyla ise periyodik bacak

hareketlerinin varlığı değerlendirilir. OUAS ile benzer belirtiler gösteren "Periyodik bacak hareketleri sendromu" tanısı ancak bu değerlendirme ile konabilir. Diğer bir önemli PSG kaydı olan uyku esnasındaki vücut pozisyon şekli ise görülen apne ve hipopne sıklığı ile yakından ilişkilidir. Özellikle sırtüstü yatış pozisyonunda apne sıklığının arttığı bilinmektedir. Bu nedenle PSG çalışmada hem yan hem sırtüstü pozisyonda kayıtlar alınmalıdır.

Tablo 3.1. AHI'e göre OUAS Sınıflaması.

AHI	OUAS Derecesi
5<	Normal
5 - 15	Hafif
15 - 30	Orta
>30	Ağır

OUAS'lı hastalarda görülmesi gereken karakteristik PSG bulguları aşağıda sıralanmıştır [10, 85]:

- Yüzeysel uykuda (N-REM evre1, 2) artma, derin uyku (N-REM evre3,4) ve REM periyodunda azalma izlenir.
- Sık tekrarlayan apneler (genellikle % 80' den fazlası obstrüktif tiptedir), hipopneler ve arousaller görülür.
- Klinik önemi olan olgularda AHI>20'dir.
- Sık tekrarlayan oksijen desaturasyonu dönemleri izlenir.
- Paradoksal göğüs ve karın hareketleri tipiktir.
- Apne sırasında kalp hızı genellikle yavaşlar ve apne sonrası dönemde hızlanır, aritmiler görülebilir.
- Solunum sesi kaydı yapılması halinde sık tekrarlayan apne epizodları ile kesilen düzensiz ve gürültülü horlama duyulur.


3.2.2. Obstrüktif Uyku Apne Sendromu Tanısında EKG

OUAS için en geçerli tanı yöntemi PSG veya diğer adıyla uyku çalışma tekniği olmasına rağmen bu çalışma tekniğinin oldukça pahalı ve zaman alıcı olduğu da

bilinmektedir. Ayrıca uyku çalışma tekniğinin uygulandığı laboratuvarların gerek ülkemizde ve gerekse diğer dünya ülkelerinde yeterli sayıda olmadığı da bilinen diğer bir gerçektir [6,10]. Dolayısıyla uyku çalışma tekniği ile OUAS tanısı ancak sınırlı sayıdaki hastaya uygulanabilmektedir. Bu tanı tekniğinin pahalı, zaman alıcı ve uygulanabileceği laboratuvar sayısının sınırlılığı gibi nedenlerden dolayı OUAS'lı hastaların büyük çoğunluğuna tanı konulmadığı bildirilmektedir [6]. Bu da OUAS tanısı için uyku çalışma tekniğine alternatif oluşturabilecek ucuz, daha az kayıt gerektiren, güvenilir ve aynı zamanda laboratuvar ortamında değil de ev ortamında uygulanabilecek tanı tekniklerine ihtiyaç duyulduğunu göstermektedir. Sadece EKG kayıtları kullanılarak geliştirilebilecek bir tanı tekniği ile bu ihtiyaçları gidermek mümkün olabilir.

OUAS'lı hastalarda gece boyunca üst solunum yollarında tekrarlayan tıkanmalar (apneler) kalbin elektriksel aktivitesi olan EKG kayıtları üzerinde değişimlere sebep olur. EKG kayıtları üzerinde izlenebilen bu değişimlerden biri kalp hızı değişkenliği (KHD) olarak da adlandırılan R-R aralıkları değişkenliğidir. KHD apnenin ilk dönemlerinde oluşan bradikardi (kalp hızı yavaşlaması) ve apne sonrası ortaya çıkan taşikardi (kalp hızı artması) ile ilişkilidir [33]. EKG kayıtlarından türetilen KHD işaretinin uyku apne tespitinde kullanılabilirliği gösterilmiştir [34-36]. Ayrıca literatürde KHD işaretinden uyku apne tespiti yapan değişik alternatif tanı yöntemleri önerilmiştir [39-41, 49-51].

KHD'nin yanı sıra OUAS'da tekrarlayan solunum tıkanmalarının EKG kayıtları üzerinde meydana getirdiği diğer bir değişim de EKG dalgalarındaki genlik değişimidir. Göğüs yüzeyinden kaydedilen EKG kayıtları, soluk alıp verme esnasında göğse bağlı elektrotun kalbe göre hareketinden ve akciğerlere hava dolup boşalırken göğüs boşluğu empedansında oluşan değişimlerden etkilenir [37, 38]. Solunum kaynaklı bu etki, EKG'de solunum döngü frekansı ile aynı frekansta genlik modülasyonu oluşturur (Şekil 3.3). Dolayısıyla EKG genliğini modüle eden solunum kaynaklı bu etki, EKG kayıtlarından elde edilmesi halinde OUAS tanısında diğer pahalı yöntemlere alternatif olarak kullanılabilir [39, 41, 50, 51, 86]. Bu çalışmada, bu etkiyi elde edebilmek için EKG'nin en karakteristik dalgası olan QRS kompleksinin altında kalan alandan faydalanıldı. EKG'nin QRS alanlarından elde edilen bu etki, solunum kaynaklı ve solunumun dolaylı bir gösterim olması sebebiyle EKG'den türetilen solunum (ETS) işareti diye adlandırılmıştır.



Şekil 3.3. Module edilen EKG işareti ve solunum işaretinin 10 saniyelik kayıtları.

KHD işaretinin EKG kaydının ardışık QRS komplekslerinin tepe aralıklarından (R-R aralıkları) ve ETS işaretinin ise EKG'nin ardışık QRS'ların altındaki alanlardan türetilmesi için QRS komplekslerinin EKG içersindeki zaman konumlarının tespit edilmesini gerektirir. Ancak QRS dalgasının zaman içersinde fizyolojik değişkenlik arz etmesi, EKG'nin çeşitli gürültüler barındırması ve ayrıca EKG'nin P ve T dalgalarının yüksek genliği gibi sebeplerden dolayı QRS kompleksinin tespiti kolay olmamaktadır. QRS'in doğru tespitinin yapılabilmesi için bu problemlerin üstesinden gelecek bir algoritma geliştirmek şarttır [87].

Literatürde QRS dalgasının zaman konumu tespitine yönelik türev, sayısal filtre ve dalgacık dönüşümü tabanlı birçok teknik önerilmiştir [88]. Nispeten daha eski olan türev tabanlı ve sayısal filtre tabanlı algoritmalar genelde iki aşamadan oluşur. İlk aşamada QRS kompleksinin tespitini zorlaştıran P, T dalgaları, taban çizgisi sapmalar ve çeşitli gürültülerin etkisini zayıflatmak için EKG işareti alçak ve yüksek geçiren filtre takımlarından geçirilir. Daha sonra filtrelenmiş EKG işareti sabit veya adapte edilebilen eşik değerleri ile karşılaştırılarak QRS komplekslerinin tespiti yapılır [89-93]. Ayrıca bu tip algoritmalarda yanlış tespiti engellemek için ilave karar kuralları kullanılır.

Son zamanlarda QRS kompleksinin tespitinde yaygın olarak kullanılmaya başlanan diğer önemli teknik dalgacık dönüşümüdür [94-96]. Dalgacık dönüşümünün en önemli avantajı çoklu ölçeklendirme özelliği ile işaretleri farklı ölçeklerdeki bileşenlerine ayırmasıdır. Dalgacık dönüşümünün bu özelliği ile EKG işareti çoklu bileşenlerini ayrılır. Daha sonra bu bileşenler arasından QRS kompleksleri ile ilgili bileşen veya bileşenler seçilir. Seçilen bu bileşenler kayan pencere ile taranarak QRS dalgasının karakteristik noktaları belirlenir. Belirlenen karakteristik noktalar değişik eşik değeri ile karşılaştırılarak

QRS komplekslerinin zaman konumları belirlenir. Bu alımda da dalgacık dönüşümüne dayalı bir algoritma kullanılarak QRS komplekslerinin zaman konumları belirlenmiştir [97,98].

Sonuç olarak OUAS’da görülen solunun tıkanma ataklarının EKG kayıtları üzerinde oluşturduğu değışimlerin (KHD ve ETS) uygun analiz teknikleri ile elde edilmesi ve işlenmesi durumunda EKG kayıtlarının OUAS tanısında kullanılabilme potansiyeli olduğunu söylemek mümkündür.

4. ÖRÜNTÜ TANIMA

Bu tezde, gerek EEG kayıtlarından uyanıklık seviyesinin belirlenmesi ve gerekse EKG kayıtlarından OUAS'ın belirlenmesi için önerilen sistemler birer örüntü tanıma sistemleridir. Bu bölümde, önerilen örüntü tanıma sistemlerinin anlaşılabilir olması için öncelikle örüntü tanıma kavramı tanıtılmıştır. Daha sonra önerilen örüntü tanıma sistemlerinin iki temel aşamasını oluşturan özellik belirleme ve sınıflandırma süreçlerinde kullanılan yöntemler tanıtılmıştır.

Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Ses sinyali, uzaktan algılama verisi, insan yüzü, retina, parmak izi, bir metin içerisindeki karakterler ve biyomedikal cihazlardan elde edilen işaretler (EEG, EKG vb), örüntüye dair bazı örneklerdir. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir [99].


Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarını insanların yaşantısında da görebiliriz: hava değişimin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip birçok etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanınması, geçmiş tecrübelerle dayalı öğrenme esaslıdır. Böylece, insanlar pratikte karşılaştığı örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Belirli bir sesi tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin birçoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinelerin yapmasını arzularlar. Örüntü tanıma, böyle akıllı ve öğrenebilen makineleri gerçekleştirmek için, çok boyutlu bir mühendislik disiplini [99].

Örüntü tanıma olayını şu şekilde tanımlayabiliriz: Aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesneleri bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırmadır. Bu bağlamda, örüntü tanımının en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir [99]. Günümüzde örüntü tanıma uygulamaları birçok alanda yaygın olarak kullanılmaktadır. Bunlara örnek olarak doppler kalp işaretlerini tanıma [99, 100, 101], EEG veya EKG sınıflama [19, 102],

haberleşme işaretlerini tanıma [103] ve radar hedef sınıflama [104] verilebilir. Örüntü tanıma olarak bilinen bu uygulamalar, makine öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır.

4.1. Örüntü Tanıma Sistemi

Genel bir örüntü tanıma sistemi, Şekil 4.1. de gösterildiği gibi 2 temel aşamadan oluşmaktadır. Bunlar sırasıyla özellik belirleme ve sınıflandırma aşamalarıdır. Özellik belirleme aşaması, elektronik algılayıcılarla toplanmış olan ham örüntüyü karakterize eden özelliklerinin elde edilebilmesi için çeşitli dönüşüm tekniklerinin gerçekleştirildiği süreçtir. Sınıflandırma aşaması ise özellik belirleme süreci sonucunda örüntüden elde edilen özellikleri kullanarak bir karar verme mekanizması (sınıflandırıcı) yardımıyla örüntünün ait olduğu sınıfın belirlendiği süreçtir.



Şekil 4.1. Bir örüntü tanıma sistemi blok diyagramı.

4.1.1. Özellik Belirleme

Özellik belirleme aşamasında amaç, çevreden algılanan yüksek boyutlu ham örüntüyü karakterize edebilen, kararlı, ölçülebilir ve mümkün olduğunca daha küçük boyutlu bir bilgi ile temsil edebilmektir. Bu süreç sonucunda ham örüntüden elde edilen bu nitelikteki bilgiye özellik vektörü adı verilir. Özellik belirleme sürecinde, ham veriyi temsil eden bu özellik kümesi elde edilirken aslında birbiriyle ilişkili üç aşamalı bir yol izlenir. Bunlar:

- **Ön işleme:** Özellik belirleme sürecinin ilk aşamasını oluşturur. Bu aşamada gerektiğinde örüntü filtrelenir, bölütlere ayrılır, çeşitli gösterim teknikleri kullanılarak işlenir, bileşenlere ayrılır veya modellenir [99].

- **Özellik çıkarma:** Özellik çıkarımı, en basit ifadeyle ön işleme aşaması sonucunda yeniden düzenlenen örüntünün boyut indirgeme işlemlerinin gerçekleştiği aşamadır. Sınıflandırılacak bir örüntü genellikle çok fazla miktarda ve gereksiz bilgi içerir. Bu durum, sınıflandırma hassasiyetini düşürürken işlem süresini de yükseltir. Bu olumsuzluğu gidermek için, örüntü bilgisi daha az miktardaki başka bir veriye dönüştürülür. Örüntüye ait fazla ve gereksiz verinin elenip, sadece örüntüyü temsil eden ve toplam veriden çok daha az sayıdaki karakteristik bilginin elde edildiği bu dönüşüme özellik çıkarma adı verilir. Karakteristik özelliklerin çıkarımı, örüntü tanıma sistemlerinin kritik tasarım aşamalarından biridir. Çıkarılan özelliklerin ayırt edici ve mümkün olduğunca az sayıda olması, tanıma işleminin daha basit sınıflandırıcılarla, daha yüksek hassasiyetle ve daha kısa sürede gerçekleştirilmesini sağlar [105].
- **Özellik seçme:** Özellik çıkarma işlemleri sonucu örüntüden elde edilen özellik kümesi ile örüntünün boyutu büyük oranda küçültülür. Ancak elde edilen bu özellik kümesi içerisindeki bazı özellikler örüntü ile ilişkisiz (irrelevant) olabileceği gibi bazı özellikler de örüntüyü temsil etmede fazlalık (redundant) teşkil edebilir [106]. Gereksiz olan ve fazlalık teşkil eden bu özellikler kullanılacak sınıflandırıcının genelleme ve ayrıştırma yeteneğini olumsuz yönde etkiler. Özellik seçme aşaması ile özellik kümesinden bu tür istenmeyen özelliklerin çeşitli yöntemler kullanılarak arındırılıp daha iyi bir özellik alt kümesi bulunması amaçlanır.

4.1.2. Sınıflandırma

Bilinmeyen bir örüntüyü tanıyabilmek için özellik belirleme aşamasından sonra sınıflandırma işlemi yürütülür. Sınıflandırma, bilinmeyen bir örüntünün hangi sınıfa dahil olduğunu, o örüntüye ait özellikleri giriş olarak kullanan bir sınıflandırıcı yardımıyla belirleme işlemidir. Sınıflandırma işlemi temel olarak iki aşamadan oluşmaktadır. Birinci aşamada, ilgilenilen örüntü sınıflarından elde edilen özellik verileri ile sınıflandırıcı eğitilerek bir karar mekanizması oluşturulur. İkinci aşamada ise herhangi bir örüntü sınıfından elde edilen özellik verisi eğitilen sınıflandırıcı girişine verilerek bunun hangi sınıfa dahil olduğuna karar verilir.

Sınıflandırma yöntemleri kullanılan öğrenme stratejisine göre genel olarak iki grupta incelenir: GÜDÜMLÜ ve GÜDÜMSÜZ öğrenme. GÜDÜMLÜ öğrenmede, ilgilenilen örüntüler ve bu örüntülerin ait olduğu sınıflar arasında bir model oluştururken eğitime işlemi sırasında ilgilenilen örüntü sınıflarının belirlenmiş özellikleri ile birlikte bu örüntülerin ait olduğu sınıflarda (etiketlerde) sınıflandırıcıya gösterilir. GÜDÜMSÜZ öğrenmede ise sınıflandırıcıya eğitim esnasında sadece ilgilenilen örüntülerin belirlenmiş özellikleri gösterilerek bunlar arasındaki benzerlik, uzaklık gibi fonksiyonlar kullanılarak bir model oluşturulur.

4.2. Özellik Belirleme Yöntemleri

Ham EEG ve EKG gibi biyolojik işaret örüntülerini kullanarak fizyolojik veya hastalıklı bir durumun tespitini yapacak bir örüntü tanıma sisteminin özellik belirleme aşaması sistemin belki de en önemli kısmını oluşturur. Ham EEG ve EKG örüntü işaretleri doğrusal olmayan ve durağan olmayan işaretler olması sebebiyle bu örüntü işaretlerini karakterize edecek asıl bilgi işaret içersinde gömülü ve zamana yayılmış durumdadır. Ayrıca bu işaret örüntülerini kullanarak fizyolojik veya hastalıklı bir durumun tespiti yüksek veri boyutu gerektiren bir işlemdir. EEG ve EKG'nin sahip olduğu bu özellikler örüntü tanıma sisteminin sınıflandırma aşamasında kullanılacak sınıflandırıcının eğitim süresini artırdığı gibi aynı zamanda genelleme ve ayrıştırma yeteneğini de azaltacaktır. Ancak, sınıflandırma aşaması öncesinde uygun özellik belirleme yöntemleri kullanılarak ham örüntünün gereksiz ve ilişkisiz bilgilerden arındırılarak kararlı ve mümkün olduğunca daha küçük boyutlu bir bilgi ile temsil edilmesi durumunda sınıflandırıcının eğitim hızı artıracığı gibi aynı zamanda genelleme ve ayrıştırma yeteneklerini de iyileştirilmiş olur [106].

Bu tez çalışmasında gerek EEG ve gerek EKG işaret örüntülerine ait özellikleri belirlemek için dalgacık dönüşümü, entropi hesaplama tekniği ve güç spektral yoğunluk kestirimine dayalı yöntemler kullanılmıştır. Tez çalışmasında kullanılan bu özellik belirleme yöntemleri aşağıda sunulmuştur.

4.2.1. Dalgacık Dönüşümü

İşaret analiz yaklaşımlarının temel amacı, uygun bir matematiksel dönüşüm uyguladıktan sonra işaret ile ilişkili daha belirgin özellikleri elde etmektir. Bu amaç için kullanılan ve en çok bilinen işaret analiz yaklaşımı FD'dir [107]. FD ile işaretin frekans içeriği bilgisi elde edilir (Şekil 4.2).



Şekil 4.2. Fourier Dönüşümü.

Ancak, bu dönüşüm sırasında işaretin zaman bilgisi kaybolur. Yani, işaret içerisindeki frekansların hangi zaman aralığında var olduğu kestirilemez. Bu durum, durağan işaretler için önemli olmamakla birlikte, EEG ve EKG gibi zaman içerisinde değişim gösterebilen durağan olmayan işaretler açısından problem teşkil etmektedir. FD'nin bu olumsuzluğunu gidermek için pencere fonksiyonu olarak tanımlanan bir sabit fonksiyonun zamanda ötelenmesi ile işaret küçük çerçevelere ayrılır ve çerçeve içinde kalan kısa süreli işaretlerin durağan olduğu kabul edilerek, her çerçeve için FD hesaplanır (Şekil 4.3). Gabor dönüşümü adı verilen bu dönüşüm 1965 yılında ortaya atılan yeni bir algoritma ile değişik pencere fonksiyonlarının kullanıldığı “Kısa zamanlı Fourier Dönüşümü” (KZFD) olarak genişletilmiştir. KZFD'ler işaretin frekans bilgisinin yanı sıra zaman bilgisini de içermektedir. Ancak bu dönüşüm sırasında kullanılan sabit pencere genişlikleri sebebiyle işaretin elde edilen zaman-frekans bilgisi sınırlı hassasiyette olmaktadır. KZFD'deki sabit genişlikteki pencere kaynaklı bu problemin üstesinden gelebilmek için DD ortaya atılmıştır.




Şekil 4.3. Kısa Zamanlı Fourier Dönüşümü.

DD işaretin ölçeklenebilir bir zaman–frekans gösterimi ile analizini sağlar ve geleneksel işaret analiz yaklaşımları (FD ve KZFD) tarafından görülemeyen detayları meydana çıkarır. DD, KZFD’nin kullanılan sabit genişlikteki pencere kaynaklı probleminin çözümünü ölçeklenebilir bir pencere kullanarak giderir. Böylece işaret içindeki düşük frekans eğilimlerini ortaya çıkarmak için geniş bir pencere, yüksek frekans detaylarını analiz etmek için sıkıştırılmış bir pencere kullanır (Şekil 4.4).



Şekil 4.4. İşaretin Dalgacık Dönüşümü analizi.

Bunun için, DD ölçeklenebilir temel bir dalgacık fonksiyonu kullanıp sabit çözünürlük problemine çözüm getirerek, işaretin bütün frekans aralıklarında optimum zaman-frekans çözünürlüğünü sağlar. [99, 108]. Dalgacık dönüşümünde yaygın olarak kullanılan ana dalgacık fonksiyon türlerinin bir kısmı Şekil 4.5’de verilmiştir.



Şekil 4.5. Yaygın olarak kullanılan ana dalgacık fonksiyon örnekleri.

DD genelde sürekli ve ayırık dalgacık dönüşüm olmak üzere iki farklı şekilde incelenir.

Sürekli Dalgacık Dönüşümü (SDD): SDD; bir $x(t)$ işaretin, $\psi(t)$ dalgacık fonksiyonunun ölçekleme ve öteleme sonucunda oluşturulan taban fonksiyonları ile analizine dayanır. Herhangi bir $x(t)$ fonksiyonun SDD aşağıda verildiği gibi,

$$W(a,b) = \int_{-\infty}^{\infty} x(t)\psi_{a,b}(t)dt \quad (4.1)$$

ifade edilir. Burada $W(a,b)$, $x(t)$ işaretinin SDD'sine karşılık gelmektedir. $\psi_{a,b}(t)$ ise taban fonksiyonunu ifade eder. $\psi_{a,b}(t)$ taban fonksiyonu, $\psi(t)$ ana dalgacık fonksiyonunun ölçekleme ve öteleme terimleri ile birlikte Denklem 4.2'de verildiği gibi tanımlanır:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (4.2)$$

Burada; a ölçekleme, b ise öteleme (dönüşüm) parametreleridir. Ölçekleme parametresi a ile dalgacık fonksiyonu $\psi(t)$ sıkıştırılır veya genişletilir. Öteleme parametresi b ise dalgacık fonksiyonunu $x(t)$ işareti üzerinde kaydırarak konumunu değiştirir.


SDD, $x(t)$ işareti ile dalgacık fonksiyonu arasında karşılıklı nasıl bir ilişki (korelasyon) olduğunu gösterir. İşaret ile dalgacık iyi eşleşmiş ise işaret ve dalgacık arasındaki ilişki yüksek olur. Bu ilişki aynı zamanda seçilen dalgacık türü ile de yakından ilişkilidir. Dolayısıyla uygulamaya göre uygun dalgacık türünün seçimi önemlidir. Sıkıştırılmış dalgacık ile işaretin detay olarak adlandırılan yüksek frekans bileşenleri elde edilirken, genişletilmiş dalgacık ile işaretin yaklaşım olarak adlandırılan düşük frekans bileşenleri elde edilir.

Ayrık Dalgacık Dönüşümü (ADD): SDD'de, ölçekleme ve öteleme parametrelerinin sürekli olarak değişmesi doğal olarak her ölçek değeri için dalgacık katsayıları hesaplama işlemini zor ve zaman alıcı kılmaktadır. SDD'deki bu dezavantajları ortadan kaldırabilmek için ADD geliştirilmiştir. ADD'de, dalgacık katsayıları hesaplanması tüm olası ölçekleme

ve öteleme parametreleri için değil de bunların bir alt kümesini oluşturan belirli noktalarda ki ayrık değerleri için yapılır. Bunun için dalgacık fonksiyonları 2^s 'nin tam sayı kuvvetleri olarak ölçeklenir ve tam sayılara ötelenerek ayrık hale getirilir. Dalgacık fonksiyonun bu şekilde ölçeklenmesi ve ötelenmesi için Denklem 4.2 ile verilen dalgacık taban fonksiyonunda $a = 2^{-s}$ ve $b = k2^{-s}$ ($k, s \in \mathbb{Z}$) alınarak yeniden düzenlenir. Böylece ayrık dönüşüm için dalgacık taban fonksiyonu:


$$\psi_{s,k}(t) = 2^{s/2} \psi(2^s t - k) \quad (4.3)$$

biçiminde ifade edilebilir. Bu işlemin gerçekleştirilmesi için **Mallat (1989)** tarafından filtrelerle dayalı etkin bir algoritma geliştirilmiştir **[109]**. Mallat'ın algoritması ardışıl yüksek ve alçak geçiren filtre çiftlerinden oluşur. Bu algoritma ile frekans spektrumu $[0 - \omega]$ olan bir $x[n]$ işaretinin ADD işlemi Şekil 4.6'da gösterilmiştir. $x[n]$ işaretini D_1 ile gösterilen detay alt bandına ve A_1 ile gösterilen yaklaşım alt bandına ayırmak için işaret $h[n]$ ile gösterilen yüksek yarım bant geçiren filtreden ve $g[n]$ ile gösterilen alçak yarım bant geçiren filtreden geçirilir ve sonra da filtre çıkışlarına $\downarrow 2$ ile gösterilen aşağı örnekleme uygulanır. Bu işleme 1. seviye ayrık dalgacık dönüşümü denir. İşlem sonucu elde edilen D_1 ve A_1 alt bantları da 1.seviye detay ve yaklaşık alt bantları olarak adlandırılır. 1. seviye ayrık dalgacık dönüşümü sonucu elde edilen A_1 yaklaşık bantı benzer şekilde ayrıştırılarak 2. seviye detay (D_2) ve yaklaşık (A_2) alt bantları elde edilir. Şekil 4.6'da görüldüğü gibi bu işlem her seferinde alçak yarım bant geçiren filtre çıkışı olan yaklaşım alt bantlarına uygulanarak tekrarlanır. Her ayrıştırma seviyesinde gerçekleştirilen filtreleme ve örnekleme işlemleri ile frekans çözünürlüğü 2 kat artırılırken zaman çözünürlüğü iki kat azaltılmış olur. Böylece Mallat ADD algoritması ile $x[n]$ işareti zaman-frekans çözünürlüğü farklı olan alt bantlara ayrıştırılmış olur. Bu şekilde işaretin bileşenlere ayrıştırılarak analizi edilmesi çoklu çözünürlük ayrıştırması olarak da bilinmektedir **[107]**.



Şekil 4.6. ADD ile işaretin alt bantlara ayrıştırılması.

İşaretin, analiz ile elde edilen bileşenlerinden yeniden oluşturulma işlemine sentez denir. Sentez işleminde, son ayrıştırma seviyesinden başlanarak tüm detay ve yaklaşık bileşenleri birleştirilerek orijinal işaret oluşturulur. İşaretin analiz bileşenlerinden yeniden oluşturulması Şekil 4.7'de verilmiştir. Yeniden oluşturma, ayrıştırma işleminin tersi olan bir işlemdir. Bu amaçla her ayrıştırma seviyesinin detay ve yaklaşık katsayıları yukarı örneklenir, alçak ve yüksek geçiren sentez filtrelerden geçirilir ve sonra toplanır. Bu işlem orijinal işaret elde edilinceye kadar ayrıştırma işlemindeki seviye sayısına devam ettirilir.



Şekil 4.7. Orijinal işaretin yeniden oluşturulması.

ADD'de kullanılan filtreler birbirinden bağımsız olmayıp birbiriyle ilişkili olan filtrelerdir. Bu ilişki,

$$H(z) = z^{-N} G(-z^{-1}) \quad (4.4)$$

$$H_1(z) = H(z^{-1}) \quad (4.5)$$

$$G_1(z) = G(z^{-1}) \quad (4.6)$$

biçimindedir. Burada $H(z)$ ve $G(z)$ sırasıyla alçak geçiren ve yüksek geçiren analiz filtrelerinin z dönüşümünü, $H_1(z)$ ve $G_1(z)$ sırasıyla alçak geçiren ve yüksek geçiren sentez filtrelerinin z dönüşümünü gösterir. N is filtre uzunluğudur. Yukarda belirtilen ilişki şartlarını sağlayan filtreler dörtlü ayna filtreler (quadrature mirror filters) olarak bilinir [110]. Bu filtre takımının tercih edilir olmasının sebebi aşağı örnekleme sonucu oluşabilen örtüşmeleri ortadan kaldırmasıdır.

4.2.2. Güç Spektral Yoğunluk Kestirimi

Güç Spektral Yoğunluk (GSY) kestirim yöntemleri, ilgilenilen sinyalin spektral bileşenleri ve güçlerinin kestirimini bulmak üzere kullanılır. GSY bulma yöntemleri genel olarak parametrik olmayan yöntemler ve parametrik yöntemler olmak üzere ikiye ayrılır. Parametrik olmayan yöntemler ile elde edilen güç spektral yoğunluğunda, işaretin kendisi direkt olarak değerlendirilir. Bu yöntemler verinin nasıl üretildiği hakkında bir varsayımda bulunmaz, dolayısıyla parametrik olmayan metotlar olarak adlandırılır. Parametrik olmayan GSY kestirim yöntemlerine örnek olarak, periodogram ve Welch metotları verilebilir. Parametrik olmayan yöntemler, HFD gibi nispeten basit algoritmalar kullanması ve hızlı çalışması gibi avantajlara sahiptir [111].

Parametrik yöntemlerde işaret, beyaz gürültü işareti uygulanmış doğrusal ayrık zamanlı bir filtrenin çıkışı olarak kabul edilir. İşaretin GSY'si işareti üretebileceği varsayılan bu filtrenin parametrelerinin kullanımı ile kestirilmektedir. Bu yöntemlere örnek Yule-Walker ve Burg yöntemleri verilebilir. Bu yöntemler, varsayımlı olarak üretilen işaretin güç spektral yoğunluğunu, çözümleme parametreleri kullanarak belirlerler. Mevcut işaretin veri uzunluğu oldukça kısa ve nispeten daha durağan olduğunda parametrik metotlar, parametrik olmayan metotlardan daha iyi sonuçlar vermektedir. Bununla birlikte parametrik metotların, seçilen modelin uygunluğunun doğrulanmasına gereksinim duyulması gibi temel bir dezavantajı vardır [111].

Bu çalışmada EEG işaretlerinin ve EKG kayıtlarından türetilen KHD ve ETS işaretlerinin DD ile elde edilen alt bantlarının GSY özelliklerini elde edebilmek amacıyla parametrik olmayan Welch yöntemi kullanılmıştır. Welch yöntemi aslında periyodogram yönteminin yeniden düzenlenerek iyileştirilmiş halidir. Dolayısıyla Welch yöntemi ile

GSY gösterimi tanıtımını anlaşılabilir kılmak için öncelikle periyodogram yönteminin kısaca tanıtımına yapmak faydalı olacaktır.

N örnekten oluşan bir ayrık zamanlı $x[n]$ işaretinin periyodogramı aşağıda verilen Denklem 4.7. ve 4.8. ile tanımlanır.

$$P_{xx}(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x[n] \cdot e^{-j2\pi fn} \right|^2 \quad (4.7)$$

$$P_{xx}(f) = \frac{1}{N} |X(f)|^2 \quad (4.8)$$

Denklemlerden de anlaşılacağı üzere periyodogram olarak adlandırılan bu şekildeki GSY gösterimi, aslında işaretin Ayrık Fourier Dönüşümü (AFD) olan $X(f)$ 'nin karesine karşılık gelmektedir. Periyodogram yöntem ile işaretin GSY gösterim başarımı işaret-gürültü oranının düşük olduğu durumlarda kötüleşir. Ayrıca AFD'nin doğasından kaynaklanan ve işaretin yapısında olmayan spektral sızma (Spectral leakage)'nın Periyodogram yöntem ile elde edilecek işaretin GSY'da görülmesi bu yöntemin diğer bir olumsuz tarafıdır. Periyodogram yöntemine dayalı GSY gösteriminin bu olumsuz tarafları Welch yöntemi ile büyük oranda giderilmektedir [111].

4.2.3. Welch Yöntemi

Welch yöntemi ile GSY gösterimi iyileştirilmiş periyodogramların ortalamasıdır [112]. Welch yöntemi ile Periyodogram GSY gösteriminde görülen spektral sızıntı azaltıldığı gibi aynı zamanda işaret-gürültü oranının düşük olduğu durumlarda GSY gösterimi iyileştirilmektedir. Welch yöntemi ile bir işaret verisinin GSY'si bulunurken aşağıda belirtilen aşamalar izlenir:

1. Öncelikle N örnek uzunluğundaki işaret verisi üst üste binmiş L tane veri parçasına bölünür. Her biri M örnek uzunluğunda olana L tane veri parçası,

$$x_i = x(n + iS), \quad n = 0, 1, \dots, M-1 \text{ ve } i = 0, 1, \dots, L-1 \quad (4.9)$$

biçiminde tanımlanır. Burada iS i. veri parçanın başlangıç noktasıdır. Eğer $S=M$ ise veri parçaları arasında üst üste binme yoktur. Veri parçaları arasında üst üste binmenin oluşabilmesi için $M>S$ olmalıdır. Eğer $S=M/2$ ise veri parçaları arasında %50 üst üste binme oluşur. Burada işareti üst üste binecek biçimde parçalara bölmenin amacı bir sonraki aşamada kullanılan pencere fonksiyonunun neden olduğu bilgi kaybını telafi etmektir. Genelde parçalar arasında üst üste binmenin %50 ile %75 arasında olması tavsiye edilmektedir [111].

2. Daha sonra üst üste bindirilmiş her parça uygun bir $w(n)$ pencere fonksiyonu ile pencerelenerek periyodogramı alınır. Böylece,

$$P_{xx}^i(f) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n)w(n)e^{-j2\pi fn} \right|^2 \quad i = 0,1,\dots,L-1 \quad (4.10)$$

ile ifade edilmiş olan her veri parçasının iyileştirilmiş periyodogramı bulunmuş olur. Burada U pencere fonksiyonunun gücü olup,


$$U = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (4.11)$$

biçiminde ifade edilir. Burada kullanılan pencere fonksiyonu ile veri parçalarının periyodogram GSY yaklaşımındaki spektral sızıntı azaltılmış olur. Literatürde bu amaç için üçgen, hanning, hamming, Blackman, Bartlett, kaiser tipi pencere fonksiyonları kullanılmaktadır. Şekil 4.8’de bu pencere fonksiyonlarından bazılarının grafiksel gösterimi verilmiştir.

3. Son aşamada ise L tane veri parçasına ait iyileştirilmiş periyodogramların ortalaması alınarak N örnek uzunluğundaki işaretin,

$$P_{xx}^W(f) = \frac{1}{L} \sum_{i=0}^{L-1} P_{xx}^i(f) \quad (4.12)$$

ile ifade edilmiş olan Welch GSY yaklaşımı elde edilmiş olur. Welch yönteminin bu son aşamasında gerçekleştirilen periyodogramların ortalaması işlemi ile gürültü içeren işaretin gürültüye karşı GSY yaklaşımı iyileştirmiş olur [111].



Şekil 4.8. Pencere fonksiyonları.


4.2.4. Entropi Hesaplama Teknikleri

Entropi, termodinamik fiziğinin bir kavramı olup bir sistemin düzensizliğinin ölçüsü olarak tanımlanır. Bir sistemin düzenli bir yapıdan düzensiz bir hale geçmesi, o sistemin entropisini artırır. Yani sistemin düzensizliği ne kadar fazla ise, o sistemin entropisi de o kadar yüksek olmaktadır. Entropi kavramının işaret işleme alanına uyarlanması ilk olarak Shannon tarafından gerçekleştirilmiştir [113]. Shannon haberleşme kanallarının doluluk kestirimi ve haberleşme işaretinin içerdiği bilgi miktarını ölçmek için entropi kavramını kullanmıştır. İşaret işleme alanındaki bu ilk uygulaması ile birlikte, özellikle durağan olmayan bir işaretin düzensizlik veya karmaşıklık bilgisini tanımlamak için entropi ideal bir tanımlayıcı olarak görülmeye başlanmıştır [99, 114].

Entropi kavramına açıklık getirebilmek için termodinamik ve işaret işleme alanındaki kullanımı karşılaştırmalı olarak Şekil 4.9'da verilmiştir. Termodinamik açısından Şekil 4.9. incelendiğinde, (a)'da kapalı kabın belirli bir bölgesine sıkıştırılmış gaz moleküllerinin (b)'de serbest bırakılmasıyla kapalı kabın tüm hacmine yayıldığı görülmektedir. Gazın moleküller dağılımının nispeten düzenli olan (a)'daki yapısı (b)'de

bozularak daha düzensiz bir yapıya kavuşmuştur. Dolayısıyla gazın entropi değeri (a) moleküller dağılım yapısında düşük, (b) moleküller dağılım yapısında yüksek olur. Termodinamikteki bu durum işaretlerin düzensizlik veya belirsizlik miktarlarını ölçmek içinde iyi bir araçtır. İşaret işleme açısından Şekil 4.9. incelendiğinde, işaret durağan (örneğin sinüzoidal bir işaret) ise frekans bölgesinde dar bir spektrum ile düşük bir entropi değerine sahip olur (a). İşaret durağan değilse (EKG işareti), frekans spektrumu geniş bir banda yayılarak yüksek bir entropi değeri oluşmasına neden olur (b) [99, 115].

Son yıllarda, entropi işaret işleme alanında yaygın olarak kullanılan bir kavram haline gelmiştir. Entropi kavramının bu alandaki uygulamalarından bazıları; JPEG görüntü kodlamada oluşabilecek gürültüyü belirlemek [116], EEG işaretlerini entropi ile analiz edilerek epilepsi hastalığının tespiti [117], EEG işaretlerinin spektral entropilerini kullanarak anestezi derinliğinin tahmini [118], 12 kanal EKG kayıtlarından entropi kriterlerine dayalı algoritmalarla kalp atımının belirlenmesi [119] ve MEG biyomedikal görüntülerin yeniden yapılandırılmasında Norm entropi yöntemi kullanarak yüksek kalitede MEG görüntüleri elde etmek [120] gibi.



Şekil 4.9. Termodinamik ve işaret işleme açısından a) Düşük, b) Yüksek entropi.

İşaret işlemede yaygın olarak kullanılan entropi hesaplama türleri: Shannon, Norm, Eşik, Logaritmik Enerji ve Sure metotlarıdır [121]. Bunlar dışında farklı entropi hesaplama

teknikleri de bulunmaktadır [122]. Yaygın olarak kullanılan entropi türleri ve bunlara ait denklemler Tablo 4.1. de verilmiştir.

Tablo 4.1. İşaret işleme alanında yaygın kullanılan entropi türleri ve bu entropi türlerine ait denklemler.

Entropi Türü	Entropi Denklemleri
Shannon Entropisi	$E(s) = -\sum_i s_i^2 \cdot \log_2(s_i^2)$ ve $\log(0) = 0$ kabul edilerek
Norm Entropisi	$E(s) = \sum_i s_i ^p$ ve $1 \leq p < 2$
Logaritmik Enerji Entropisi	$E(s) = \sum_i \log_2(s_i^2)$ ve $\log(0) = 0$ kabul edilerek
Eşik Entropisi	$E(s) = \sum_i E(s_i)$ ε pozitif bir eşik değeri olup $ s_i > \varepsilon \Rightarrow E(s_i) = 1$ ve $ s_i \leq \varepsilon \Rightarrow E(s_i) = 0$
Sure Entropisi	$ s_i \leq \varepsilon \Rightarrow E(s) = \sum_i \min(s_i^2, \varepsilon^2)$ burada ε pozitif bir eşik

Tablo 4.1. de verilen entropi denklemlerinde, s işareti ve s_i de işaretin i . katsayısını ifade eder. Bu entropi hesaplama tekniklerinin, işaret işlemedeki kesin kullanım alanları belirli olmayıp, uygulamalara göre başarımları değişmektedir [99].

4.3. Sınıflandırma Yöntemleri

Daha öncede ifade edildiği gibi Sınıflandırma, bilinmeyen bir örüntünün hangi sınıfa dahil olduğunu, o örüntüye ait özellikleri giriş olarak kullanan bir sınıflandırıcı yardımıyla belirleme işlemidir. Bir örüntü tanıma sisteminin başarımı, örüntüyü betimlemek için kullanılan özellik belirleme yöntemini bağlı olmakla birlikte kullanılan sınıflandırma yöntemi ile de yakından ilişkilidir. Ancak, örüntü tanıma problemlerinde hangi sınıflandırma yönteminin en iyi ya da en uygun olduğu kesin olarak söylenemez. Çünkü örüntünün çeşidi, örüntüden elde edilen özelliklerin yapısı ve boyutu, işlem süresi ve karmaşıklığı gibi faktörlere göre tercih edilmesi gereken sınıflandırma yöntemi farklılık gösterebilir [105]. Yaygın olarak kullanılan sınıflandırma yöntemlerinden bazıları Bayes,

doğrusal sınıflandırıcılar, doğrusal olmayan sınıflandırıcılar, YSA, saklı Markov modeller, DVM, karar ağaçları ve ANFIS dir [123-127].

Bu tez çalışmasında, EKG biyolojik işaret örüntülerinden OUAS hastalığının tespitini yapan örüntü tanıma sisteminin sınıflandırma aşamasında YSA ve EKK-DVM'ye dayalı sınıflandırma yöntemleri kullanılmıştır. EEG biyolojik işaret örüntülerinden uyanıklık seviyesinin tespitini yapan örüntü tanıma sisteminin sınıflandırma aşamasında ise YSA ve EKK-DVM sınıflandırma yöntemlerinin yanı sıra ANFIS sınıflandırma yöntemi de kullanılmıştır. Tez çalışmasında kullanılan bu sınıflandırma yöntemlerinin tanıtımı aşağıda sunulmuştur.


4.3.1. Yapay Sinir Ağları

İnsan beyninin öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfetme gibi üstün özellikleri, bilim insanlarını beynin yapısı ve işleyişinin matematiksel modelini oluşturmaya yönelik çalışmalara sevk etmiştir. Bu konuda yapılan ilk çalışmalar beynin temel yapı taşı olan beyin hücresi (biyolojik nöron) yapısı ve işleyişinin matematiksel olarak modellenmesi üzerine yoğunlaşmıştır. Bu çalışmaların ortaya koyduğu bulgular ve özellikle bilgisayar teknolojisindeki gelişmelerin getirdiği avantajlarında katkısıyla nöronun matematiksel modellerine dayanan ve dolayısıyla insan beyninin öğrenme, ilişkilendirme, sınıflandırma ve genelleme yeteneklerine benzer işlevleri yerine getirebilen bilgisayar sistemleri geliştirilmiştir. Bu özelliklere sahip olarak geliştirilen bilgisayar sistemleri YSA olarak adlandırılmıştır. Genel anlamda YSA, birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden (yapay nöron) oluşan bir yapı şeklinde ifade edilir. Bu yapı içerisinde yer alan yapay hücreler arasındaki her bağlantının bir değeri bulunur. YSA yapılarında öğrenme yoluyla elde edilen bilgi bu bağlantı değerlerinde saklanır. Dolayısıyla bu yapılarda öğrenilen bilgi tüm ağa yayılmış durumdadır. Bu durum YSA yapılarının dağıtık hafızalı olduğunu gösterir [128, 129].

YSA'nın tarihsel gelişimi, 1940'lı yılların başlarında ilk yapay hücre modelinin oluşturulması ile başlamıştır [128, 130]. 1980'li yılları başlarına varıldığında ise birçok farklı yapay hücre modeli ve yine bunlara dayalı YSA modelleri geliştirilmiştir. Ancak geliştirilen bu modeller genelde teorik temelde olduğundan uygulama alanları da sınırlı olmuştur [128]. YSA ilgili asıl tarihsel önemdeki adım çok katmanlı algılayıcı (ÇKA) YSA

modelinin bulunup geliştirilmesi ile olmuştur [128, 131]. Çünkü daha öncesindeki YSA modelleri ile çözümü mümkün olmayan XOR problemi bu model ile çözülmüştür. 1990'li yılların başlarına gelindiğinde ÇKA dışında LVQ (Learning Vector Quantization), SOM (Self-Organizing Maps), RBF (Radial Basis Functions), PNN (Probabilistic Neural Networks), GRNN (Generalized Regression Networks) vb gibi birbirinden farklı 30 civarında yeni YSA modelinin geliştirilmesi ile YSA bir bilim dalı olarak belli bir olgunluğa erişmiştir [128]. Günümüzde YSA artık teorik ve laboratuvar çalışmaları olmaktan çıkarak tıp, mühendislik, finans vb gibi çok farklı alanlardaki güç ve karmaşık olan problemlerin çözümü için kullanılan faydalı bilgisayar sistemleri olmuştur. YSA'nın bu farklı alanlardaki genel kullanım amaçlarını, kendisine sunulan veriyi sınıflandırma, ilişkilendirme, yorumlama, filtreleme, tanıma ve eşleştirme şeklinde kategorize etmek mümkündür [128].

Daha öncede ifade edildiği gibi, YSA yapı olarak biyolojik nörondan esinlenerek oluşturulan yapay hücrelerden oluşur. Mühendislik biliminde işlem elemanı olarak da adlandırılan bir yapay hücre modeli 5 temel kısımdan oluşur (Şekil 4.10). Bunlar sırasıyla girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkıştır.




Şekil 4.10. Bir yapay hücre modeli.

Şekil 4.10. da verilen hücre modelinin birinci kısmı olan girişler, dış dünyadan, hücrenin kendisinden (geri besleme) veya YSA içerisindeki diğer yapay hücre çıkışlardan gelen sayısal bilgileri temsil eder. Hücrenin ikinci kısmı olan ağırlıklar hücreye gelen giriş bilgisinin önemini ve hücre üzerindeki etkisini gösterir. Örneğin Şekil 4.10. da verilen

hücre bir YSA ağı içersindeki k. hücre olarak düşünülürse, x_1 girişinin bu hücre üzerindeki etkisi w_{k1} ağırlığı ile belirlenir. Daha genel bir ifade ile YSA'nın öğrenme yoluyla herhangi bir olay hakkında edindiği genelleme bilgisi hücrelerin ağırlıklar kısmında saklanır. Ağırlıklar değişken veya sabit değerler olabilirler. Üçüncü kısım olan toplama fonksiyonu, hücreye gelen net girişi hesaplayan bir fonksiyondur. Net giriş genellikle girişlerden gelen bilgilerin ilgili bağlantıların ağırlıkları ile çarpılıp toplanması ile belirlenir. Buna göre YSA'nın k. yapay hücresine ait net giriş,

$$I_k = \sum_{j=1}^n w_{kj} x_j + \theta_k \quad (4.13)$$

şeklinde ifade edilir. Burada; w_{kj} , x_j ve θ_k sırasıyla k. yapay hücresine ait ağırlıkları, girişleri ve eşik değerini gösterirler. Burada kullanılan θ_k eşik değeri ile tüm girişlerin sıfır olduğu durumlarda yapay hücre çıkışının sıfır olması zorunluluğu ortadan kaldırılır [132]. Hücrenin dördüncü kısmını oluşturan aktivasyon fonksiyonu ($\psi(.)$), hücreye gelen net girişi (I_k) işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı (y_k) belirler. Hücrenin gerçekleştireceği işleme göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Örneğin YSA'nın ÇKA modelinde bu fonksiyonun türevinin alınabilir tipte bir fonksiyon olmasını şart koşturmaktadır. Yaygın olarak kullanılan aktivasyon fonksiyon tiplerinden 4 tanesi Şekil 4.11'de gösterilmiştir.



Şekil 4.11. YSA için aktivasyon fonksiyonları: (a) basamak, (b) doğrusal, (c) log-sigmoid, (d) tan-sigmoid.

Yapay hücrenin son kısmını oluşturan çıkış (y_k), Denklem 4.14'de ifade edildiği üzere aktivasyon fonksiyonu tarafından belirlenen çıktı değerini diğer işlem elemanlarına veya dış dünyaya aktarma işlevini görür.

$$y_k = \psi(I_k) \quad (4.14)$$

Bir yapay hücrenin birden fazla girişi olmasına rağmen sadece bir çıktısı olmaktadır.

Günümüzde onlarca sayıda birbirinden farklı YSA modeli bulunmakta ve bu sayı her geçen gün artmaktadır [99, 128, 133]. Bütün YSA modelleri yapay hücrelerin bir araya gelmesinden oluşur. Bir YSA modelini diğer modellerden farklı kılan kıstaslar ise modelin sahip olduğu ağ yapısı, modelin eğitim esnasında izlediği öğrenme stratejisi ve bu stratejiye dayalı kullandığı öğrenme algoritmasıdır. YSA modelleri kendi içerisinde bu kıstaslara göre tasnif edilirler. Burada ağ yapısı ile kast edilen ağı oluşturan hücrelerin ağ içerisindeki diziliş düzeni ve hücrelerin birbiriyle olan bağlantı şeklidir. Ağ yapılarında yapay hücreler ya tamamen birbirleri ile bağlantılı ya da yerel olarak gruplar halinde bağlantılı olabildikleri gibi değişik şekilde de birbirleri ile bağlantı halinde olabilir. Ağ içinde bilgi akışı bu bağlantılar üzerinden tek yönlü olduğu gibi (ileri beslemeli ağ yapısı), çift yönlü de olabilir (geri beslemeli ağ yapısı). Genel itibarıyla yapay hücreler 3 katman halinde ve her katman içinde paralel olarak bir araya gelerek YSA ağ yapısını oluştururlar. Bu katmanlar; ağı dış dünya ile bağlantısını kuran giriş katmanı, gelen bilgileri işleme kabiliyetine sahip ara katmanlar ve ağına kararlarını dış dünyaya aktaran çıkış katmanıdır. Çoğu YSA yapılarının giriş katmanında herhangi bir bilgi işleme söz konusu olmaz. Dolayısıyla bu katmandaki yapay hücreler dış dünyadan aldıkları bilgiyi herhangi bir değişikliğe uğratmadan doğrudan ara katmanlardaki yapay hücrelere aktarırlar. Burada sözü edilen bilgi, YSA'nın ağ yapısını oluşturan yapay hücreler arasındaki bağlantı hatları üzerinde bulunan ağırlıklarla ifade edilir. Bağlantı ağırlık değerleri ile ifade edilen bu bilgi YSA'nın ilgilenilen problemin örnekleri ile eğitilmesi sonucu belirlenir.

Bir YSA modeli ilgilenilen herhangi bir problemin çözümü için uygulamaya alınmadan önce eğitilmesi ve performansının test edilmesi gerekir. YSA'nın eğitilmesi, yukarıda değinildiği gibi YSA'da yapay hücrelerin bağlantı ağırlık değerlerinin belirlenmesi işlemidir. Başlangıçta bu ağırlık değerleri rasgele atanır. YSA kendisine ilgilenilen problem ait örnekler gösterildikçe bu ağırlık değerlerini değiştirirler. Amaç ağı gösterilen örnekler için doğru çıktılar verecek ağırlık değerlerini bulmaktır. Bunun için genellikle örnekler ağı defalarca gösterilerek en doğru ağırlık değerleri bulunmaya çalışılır. YSA'nın doğru ağırlık değerlerini ulaşması örneklerin temsil ettiği problem hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine ağı öğrenmesi denir. Ağırlıkların değerlerinin değişmesi


belirli kurallara göre yürütülür. Bu kurallara öğrenme algoritmaları denir. Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini veya başka bir ifadeyle ağın performansını ölçmek için yapılan işleme ise ağın test işlemi denir. Bu işlem için ağın daha önceden görmediği problem ait veri örnekleri kullanılır. Test işlemi sırasında ağın ağırlık değerleri değiştirilmez. Test örnekleri ağa gösterilir ve ağ eğitim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekler için çıktılar üretir. Elde edilen çıktıların doğruluk değerleri ağın problemi öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir. Eğitim için kullanılan problem ait örneklerle eğitim seti ve test için kullanılan problem ait örneklerle ise test seti adı verilir.

YSA'nın karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Ancak, bütün modeller için geçerli olan genel karakteristik özellikleri vardır. Bunlardan bazıları aşağıda verildiği gibi sıralanmıştır [128]:

- YSA'nın temel işlem elemanı olan yapay hücre doğrusal değildir. Dolayısıyla yapay hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. YSA'nın sahip olduğu bu özellik onu doğrusal olmayan problemlerin çözümü için önemli araçlardan biri haline getirmiştir.
- YSA'da bilgi ağın bağlantılarının ağırlık değerleri ile ölçülmekte ve bu bağlantılarda saklanmaktadır. Dolayısıyla bu bilgi ağa yayılmış durumdadır. Bu da YSA'da dağıtık hafıza söz konusu olduğunu gösterir. YSA ilgilenilecek herhangi bir problemin çözümünde kullanılırken öncelikler bu hafıza bilgisinin oluşturulması gerekir. Bir başka ifadeyle ağın bağlantı değerlerinin ayarlanması gerekir. YSA, bu bağlantı değerlerinin ayarlanmasını öğrenme yolu ile gerçekleştirir.
- YSA örnekleri kullanarak öğrenir. Bunun için ilgilenilen problemle ilgili örneklerin belirlenmesi gerekir. Örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe kavuşturulurlar. YSA'nın bu şekilde bilinen örneklerden belirli bilgileri çıkartarak/öğrenerek kavuştuğu genelleme yeteneği sayesinde aynı problemle ilgili bilinmeyen örneklerle de çözüm bulabilir. İlgilenilen problemle ilgili örnekler bulunamıyorsa veya yok ise YSA'nın eğitilmesi/öğrenmesi veya başka bir ifade ile genelleme yeteneğine kavuşturulması mümkün değildir.

- YSA öğrenme sürecini belirlenen bir öğrenme stratejisine ve buna dayalı bir öğrenme kuralına göre gerçekleştirir. Öğrenme stratejisi, probleme ait öğrenilecek örneklerin eğitim esnasında ağı nasıl sunulacağını gösterir. Örneklerin girdi ve bu girdilere karşı gelen hedef çıktıları ağı eğitim esnasında birlikte gösteriliyorsa buna güdümlü öğrenme stratejisi denir. Örneklerin sadece girdi bileşeni ağı eğitim esnasında gösteriliyor ise buna güdümsüz öğrenme stratejisi denir. Öğrenme kuralları ise belirlenen öğrenme stratejisine dayalı olarak, YSA'nın örneklerden eğitilerek belirlenmek istenen ağırlık değerlerinin nasıl ayarlanacağını detaylarını gösteren optimizasyon algoritmalarıdır. Bu algoritmaların oluşturulma biçimleri modelden modele göre değişebilmektedir.
- YSA eksik bilgi ile çalışabilme ve hatalara karşı toleranslı olma özelliğine sahiptir. Daha öncede belirtildiği gibi YSA birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşurlar ve bilgi bu yapının bağlantılarında saklanır. Dolayısıyla eğitilmiş YSA'nın bazı bağlantılarının veya bazı hücrelerinin etkisiz hale gelmesi, ağı çalışmasını durdurmadığı gibi ağı doğru bilgi üretmesini de önemli derecede etkilemez.

Daha önceden de belirtildiği gibi çok sayıda YSA modelleri geliştirilmiştir. Geliştirilen bu YSA modellerinin tümünü örüntü sınıflandırıcı olarak kullanmak mümkündür. Ancak, bunlar arasında en yaygın ve en güçlü sınıflandırıcı YSA'nın Çok katmanlı algılayıcı (ÇKA) modelidir. Bu model tüm YSA uygulamalarının %90'nını kaplamaktadır [99, 124]. Ayrıca bu modelin mühendislik problemlerinin %95'ine çözüm üretebilecek nitelikte olduğu belirtilmektedir [128]. Rumelhart ve arkadaşları tarafından geliştirilen bu model kullandığı öğrenme algoritması nedeniyle hata yayma modeli veya geriye yayım modeli (backpropagation network) olarak da bilinir [131]. ÇKA modelinin ağ yapısı Şekil 4.12'de gösterildiği gibidir.



Şekil 4.12. ÇKA modeli.

Şekil 4.12’den de görüldüğü gibi ÇKA ileriye doğru bağlantılı ve giriş, ara ve çıkış olarak adlandırılan 3 katmandan oluşan ağ yapısına sahiptir. Giriş katmanı dış dünyadan gelen bilgileri herhangi bir işleme tabi tutmadan doğrudan ara katmana iletir. Bu katmandaki her hücrenin bir girdisi ve bir çıktısı vardır. Her hücrenin çıktısı bir sonraki katmanın bütün hücrelerine gönderilir. Ara katman ise giriş katmanından gelen bilgileri işleyerek çıkış katmanına gönderir. Bir ÇKA ağında birde fazla sayıda ara katman söz konusu olabilir. Ağın girdi katmanında olduğu gibi bu katmanda da her hücrenin çıktısı bir sonraki katmanın bütün hücrelerine gönderilir. Ağın son katmanı olan çıkış katmanı ise ara katmandan gelen bilgileri işleyerek ağa giriş katmanından sunulan girdi için ağın ürettiği çıktıyı bulur. Bu çıktı dış dünyaya verilir. ÇKA ağının giriş ve çıkış katmanlarında kaç tane hücrenin olması gerektiğine ilgilenilen probleme bakılarak karar verilir. Ara katman sayısı ve her ara katmandaki hücre sayısının kaç olması gerektiğini gösteren bir yöntem yoktur. Bunlar deneme yanılma yolu ile belirlenir.

ÇKA ağı güdümlü öğrenme stratejisine göre çalışır. Yani, ağa eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi beklenen çıktılar uygulanır. Ağın görevi bu

stratejiye dayalı bir öğrenme kuralı kullanarak kendisine gösterilen her girdiye karşılık beklenen çıktıyı üretmesini sağlayacak ağırlık değerlerini bulmaktır. ÇKA öğrenme kuralı olarak hata geriye yayma algoritmasını kullanır. Bu algoritma en küçük kareler yöntemine dayalı delta öğrenme algoritmasının ÇKA ağına uyarlanmış halidir. Bu algoritmaya göre ağın eğitilebilmesi için bir eğitim kümesine ihtiyaç duyulur. Eğitim kümesi ilgilenilen sınıflandırma problemine ait örneklerden oluşur. Eğitim kümesini oluşturan örneklerin her biri girdi ve çıktı olmak üzere iki ayrı bileşenden oluşur. Girdi bileşeni, örneğin ait olduğu sınıfın verisini gösterir. Çıktı bileşeni ise örneğin hangi sınıfa ait olduğunun nümerik etiket bilgisini gösterir. Eğitim esnasında örneklerin girdi bileşenleri ağın girişine verilerek ağdan bu girdilere karşılık gelen çıktı bileşenlerini üretmesi beklenir. Bir ÇKA YSA modelinin hata geriye yayma algoritmasıyla eğitiminin nasıl gerçekleştiğini göstermek için şekil 4.12’de verilen ÇKA modeli temel alınacaktır. Şekildeki ÇKA modelinin giriş ve çıkış katmanını ile birlikte bir ara katman da bulunmaktadır. Daha önceden de belirtildiği üzere ara katman sayısı birden fazla olabilir. Ancak burada eğitim algoritmasının kolay anlaşılabilmesi için ara katman sayısı olarak 1 ara katmana sahip ÇKA modeli kullanılmıştır. Hata geriye yayma algoritması ile ÇKA ağının eğitiminin nasıl gerçekleştiğini göstermeden önce ağ üzerindeki değişkenlerin tanıtılması gerekir. Bu değişkenlerin tanıtımı aşağıda verildiği gibidir;

x_{vn} ve d_{vk} : $v=1,...,V$, $n=1,...,N$ ve $k=1,...,K$ olmak üzere x_{vn} ve d_{vk} sırasıyla V tane örnekten oluşan eğitim kümesinin N boyutlu girdi ve K boyutlu çıktı (beklenen çıktı) bileşenlerini gösterirler. Eğitim kümesindeki örneklerin girdi boyutu aynı zamanda ÇKA ağının giriş katmanındaki yapay hücre sayısını belirler. Yine, eğitim setindeki örneklerin beklenen çıktı bileşenin boyutu aynı zamanda ÇKA ağının çıkış katmanındaki yapay hücre sayısını belirler.

$\bar{w}_{jn}$: $j=1,...,J$ olmak üzere, ağın ara katmanındaki j . hücresi ile giriş katmanındaki n . hücresi arasındaki ağırlık bağlantısını gösterir. Buna göre ara katmandaki hücre sayısı J tanedir.

w_{kj} : Ağın çıkış katmanındaki k . hücresi ile ara katmanındaki j . hücresi arasındaki ağırlık bağlantısını gösterir.

θ_j ve θ_k : θ_j ara katmandaki j . yapay hücresine ait +1 sabit girişli eşik biriminin ağırlığını gösterirken θ_k ise çıkış katmanındaki k . yapay hücresine ait +1 sabit girişli eşik biriminin ağırlığını gösterir.

$\bar{y}_{vj}$: Eğitim kümesindeki v . örneğin girdi bileşenin ağ girişine verilmesi ile ağın ara katmandaki j . yapay hücresinde oluşan çıkışı gösterir.

y_{vk} : Eğitim kümesindeki v . örneğin girdi bileşenin ağ girişine verilmesi ile ağın çıkış katmandaki k . yapay hücresinde oluşan çıkışı ifade eder.

Hata geriye yayma algoritması ile ÇKA ağının eğitimi: Standart hata geriye yayma algoritmasıyla ağın eğitimi üç temel aşamadan oluşur. Bunlar; ağın eğitim kümesinin girdi bileşenlerine karşılık ürettiği çıktıların hesaplandığı ileriye doğru hesaplama, ağın ürettiği çıktılarıyla kendisinden beklenen çıktıları karşılaştırarak hata hesaplama ve hesaplanan bu hatayı geriye doğru yayarak ağırlık değerlerinin güncellenmesi [129, 134].

1. İleriye doğru hesaplama: Bu aşama eğitim kümesindeki bir örneğin girdi bileşeninin ağın giriş katmanına girdi olarak verilmesi ile başlar. Gelen girdiler hiçbir değişikliği uğramadan ara katmana gönderilir. Ara katmandaki her yapay hücre giriş katmanındaki bütün yapay hücrelerden gelen bilgileri bağlantı ağırlıklarının ($\bar{w}_{jn}$) etkisiyle alır ve toplar. Toplama işlemi ile ara katmandaki her hücrenin net girdisi bulunmuş olur. Ara katmandaki j . bir hücrenin net girdisi,

$$\bar{I}_{vj} = \sum_{n=1}^N (\bar{w}_{jn} x_{vn} + \theta_j) \quad (4.15)$$

bağıntısı ile ifade edilir. Ara katmandaki her hücrenin net girdisi sahip oldukları aktivasyon fonksiyonları tarafından işlenerek hücrelerin çıkışına verilir. Böylece ara katmandaki j . hücrenin çıktısı,

$$\bar{y}_{vj} = \psi_j(\bar{I}_{vj}) \quad (4.16)$$

bağıntısı ile ifade edilir. Burada ψ_j ara katmanın j . hücresine ait türevi alınabilir aktivasyon fonksiyonunu gösterir. Ağın çıkış katmanındaki her hücrenin çıktısını bulabilmek için ise ara katman ait her hücrenin çıktısı çıkış katmanına gönderilir. Çıkış

katmanındaki her hücre ara katmandan gelen bu çıktıları bağlantı ağırlıklar (w_{kj}) etkisiyle alıp toplayarak kendisi için net girdi oluşturur. Çıkış katmanındaki herhangi bir hücre için elde edilen net girdi,

$$I_{vk} = \sum_{j=1}^J (w_{kj} \bar{y}_{vj} + \theta_k) \quad (4.17)$$

biçiminde ifade edilir. Çıkış katmandaki her hücrenin bu net girdisi daha sonra sahip olduğu aktivasyon fonksiyonundan geçirilerek çıkışına verilir. Buna göre çıkış katmanındaki k . hücrenin çıkışı,

$$y_{vk} = \psi_k(I_{vk}) \quad (4.18)$$

biçiminde ifade edilmiş olur. Burada ψ_k çıkış katmanına ait k . hücrenin türevi alınabilir aktivasyon fonksiyonunu gösterir. Bulunan bu son ifade ile geri yayılım algoritmasının ileri doğru hesaplama aşaması tamamlanmış olur.

2. Hata hesaplama ve geriye yayma: Bu aşamada ağa uygulanan eğitim örneğinin ilk bileşeni için ağın ürettiği çıktılar (y_{vk}) ağın beklenen çıktıları (d_{vk}) ile karşılaştırılır. Bunlar arasında oluşan fark hata olarak kabul edilir. Amaç, bu hataya göre tanımlanan bir maliyet fonksiyonunu minimize edecek şekilde ağın yapay hücre ağırlıklarını ayarlamaktır. Maliyet fonksiyonu genelde hataların karelerinin toplamı (toplam karesel hata) şeklinde ifade edilir. Buna göre ağa uygulanan eğitim setinin v . örneği için ağ çıkışında oluşan toplam karesel hata,

$$E_v = \frac{1}{2} \sum_{k=1}^K (d_{vk} - y_{vk})^2 \quad (4.19)$$

bağıntısı ile ifade edilir. Toplam karesel hatayı minimize etmek için bu hatanın kendisine neden olan yapay hücrelere dağıtılması gerekir. Bu ise yapay hücrelerin ağırlıklarının değiştirilmesi demektir. Bunun içinde toplam karesel hatanın ağırlıklara göre türevinin alınarak elde edilen eğimlere göre ağırlık değerlerinin güncellenmesi gerekir. Ağırlıkların

güncellenmesi için gerekli eğim değerleri çıkış katmanından ara katmana doğru hesaplanır. Buna göre ara katmanı çıkış katmanına bağlayan bağlantı ağırlıklarının (w_{kj}) güncellenmesi için gerekli eğim,

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial y_{vk}} \frac{\partial y_{vk}}{\partial I_{vk}} \frac{\partial I_{vk}}{\partial w_{kj}} \quad (4.20)$$

biçiminde zincir kuralına göre kısmi türevlerle belirlenir. (4.20) bağıntısındaki çarpanların açılımı ise sırasıyla,

$$\frac{\partial E}{\partial y_{vk}} = \frac{\partial}{\partial y_{vk}} \left[\frac{1}{2} \sum_{k=1}^K (d_{vk} - y_{vk})^2 \right] = -(d_{vk} - y_{vk}) \quad (4.21)$$

$$\frac{\partial y_{vk}}{\partial I_{vk}} = \frac{d\psi_k(I_{vk})}{dI_{vk}} = \psi'_k(I_{vk}) \quad (4.22)$$

$$\frac{\partial I_{vk}}{\partial w_{kj}} = \frac{\partial}{\partial w_{kj}} \left[\sum_{j=1}^J (w_{kj} \bar{y}_{vj} + \theta_k) \right] = \bar{y}_{vj} \quad (4.23)$$

bağıntıları ile ifade edildiği gibi olur. Çarpanların (4.21)-(4.23) bağıntıları ile gösterilen açılımları, (4.20) bağıntısındaki yerlerine yazıldığında ara katmanı çıkış katmanına bağlayan ağırlıkların güncellenmesi için gerekli eğim,

$$\frac{\partial E}{\partial w_{kj}} = -(d_{vk} - y_{vk}) \psi'_k(I_{vk}) \bar{y}_{vj} = -\delta_{vk} \bar{y}_{vj} \quad (4.24)$$

biçiminde belirlenmiş olur. Belirlenen bu eğimdeki δ_{vk} çarpanı çıkış katmanındaki k . hücrenin yöresel hatası diye adlandırılır. Çıkış katmanındaki yapay hücrelere ait eşik birimlerinin ağırlıklarını (θ_k) güncellemek için gerekli eğim hesaplaması da ara katmanı çıkış katmanına bağlayan ağırlıkların eğim hesaplamasındaki gibi yapılır. Buna göre çıkış katmanına ait eşik birimlerinin ağırlıklarını güncellenmesi için gerekli eğim,

$$\frac{\partial E}{\partial \theta_k} = -\delta_{vk} \quad (4.25)$$

biçiminde ifade edilir. Çıkış katmanındaki yapay hücreler ait ağırlıkların (w_{kj} , θ_k) güncellenmesi için gerekli eğimler hesaplandıktan sonra, ara katmana ait hücrelerin ağırlıklarının ($\bar{w}_{jn}$, θ_j) güncellemesi için gerekli eğim hesabına geçilir. Bunlardan giriş katmanını ara katmana bağlayan ağırlıklarının (w_{jn}) eğim hesabı için aşağıda belirtilen (4.26) bağıntısından faydalanılır.

$$\frac{\partial E}{\partial \bar{w}_{jn}} = \frac{\partial E}{\partial y_{vj}} \frac{\partial y_{vj}}{\partial \bar{I}_{vj}} \frac{\partial \bar{I}_{vj}}{\partial \bar{w}_{jn}} \quad (4.26)$$

(4.26) bağıntısındaki ilk çarpanın açılımı, (4.17)-(4.19) bağıntıları göz önüne alındığında,

$$\frac{\partial E}{\partial y_{vj}} = \frac{\partial}{\partial y_{vj}} \left[\frac{1}{2} \sum_{k=1}^K (d_{vk} - y_{vk})^2 \right] = - \sum_{k=1}^K (d_{vk} - y_{vk}) \psi'_k(I_{vk}) w_{kj} \quad (4.27)$$

biçiminde ifade edilir. (4.26) bağıntısındaki ikinci çarpanın açılımı ise (4.16)'da verilen ifade göz önüne alındığında,

$$\frac{\partial y_{vj}}{\partial \bar{I}_{vj}} = \psi'_j(\bar{I}_{vj}) \quad (4.28)$$

biçiminde ifade edilir. (4.26) bağıntısının son çarpanı olan üçüncü çarpanın açılımı ise, (4.15)'de verilen ifade göz önüne alındığında,

$$\frac{\partial \bar{I}_{vj}}{\partial w_{jn}} = x_{vn} \quad (4.29)$$

biçiminde ifade edilir. Çarpanların (4.27), (4.28) ve (4.29) bağıntıları ile gösterilen açılımları (4.26) bağıntısında yerlerine yazıldığında giriş katmanını ara katmana bağlayan bağlantı ağırlıklarının güncellenmesi için gerekli eğim ifadesi,

$$\frac{\partial E}{\partial w_{jn}} = - \left(\sum_{k=1}^K (d_{vk} - y_{vk}) \psi'_k(I_{vk}) w_{kj} \right) \psi'_j(\bar{I}_{vj}) x_{vn} = -\delta_{vj} x_{vn} \quad (4.30)$$

biçiminde belirlenmiş olur. Buradaki δ_{vj} çarpanı ara katmandaki j . hücrenin yöresel hatası olarak isimlendirilir. Ara katmandaki yapay hücelere ait eşik birimlerinin ağırlıklarının (θ_j) eğimi hesaplaması da giriş katmanını ara katmana bağlayan ağırlıkların eğim hesaplamasındaki gibi yapılır. Buna göre ara katmanına ait eşik birimlerinin ağırlıklarını güncellenmesi için gerekli eğim ifadesi de,

$$\frac{\partial E}{\partial \theta_j} = -\delta_{vj} \quad (4.31)$$

biçiminde belirlenir.

3. Ağırlık değerlerinin güncellenmesi: Algoritmanın bu aşamasında ise 2. aşamada karesel hatanın ağırlıklara göre türevi alınarak bulunan eğim değerlerinden faydalanılarak ağırlıklar değiştirilir. Ağırlıkların değiştirilme işlemi için (4.32)'de verilen genel ifade yapısı kullanılır.

$$W^{s+1} = W^s + \beta \Delta W \quad (4.32)$$

$$\Delta W = - \frac{\partial E}{\partial W} \quad (4.33)$$

(4.32)'deki ağırlık değiştirme işleminde, W^{s+1} : ağırlığın değiştirilme sonrası aldığı yeni değerini, W^s : ağırlığı değiştirilme öncesi değerini, β : öğrenme oranını ve ΔW : (4.33)'de gösterildiği gibi karesel hatanın ağırlıklara göre türevinin negatif değerini gösterir. β ve ΔW 'nin çarpımından oluşan $\beta \Delta W$ terimi ise ağırlıkların değişim miktarını gösterir. Buna göre algoritmanın 2. aşamasında (4.24), (4.25), (4.30) ve (4.31) bağıntıları ile ifade edilen karesel hatanın ağırlıklara göre kısmi türev değerleri kullanılarak ağırlıkların bir sonraki iterasyon için yeni değerleri,

$$w_{kj}^{s+1} = w_{kj}^s + \beta \delta_{vk} \bar{y}_{vk} \quad (4.34)$$

$$\theta_k^{s+1} = \theta_k^s + \beta \delta_{vk} \quad (4.35)$$

$$w_{jn}^{s+1} = w_{jn}^s + \beta \delta_{vj} x_{vn} \quad (4.36)$$

$$\theta_j^{s+1} = \theta_j^s + \beta \delta_{vj} \quad (4.37)$$

olarak belirlenir. Burada; (4.34) bağıntısı ara katmanı çıkış katmanına bağlayan ağırlıkların, (4.35) bağıntısı çıkış katmanı hücrelerine ait eşik ağırlıkların, (4.36) bağıntısı giriş katmanını ara katmana bağlayan ağırlıkların ve (4.37) bağıntısı ara katman hücrelerine ait eşik ağırlıkların yeni ağırlık değerlerini gösterirler. Bu yeni ağırlık değerlerinin bulunması ile algoritmanın 3 aşamadan oluşan bir çevrimi veya iterasyonu tamamlanmış olur. Bundan sonra eğitim kümesini oluşturan her örnek için 3 aşamadan oluşan bu çevrim tekrarlanır. Her çevrim işlemi sonucunda ağırlıkların bütün ağırlıklarının değerleri güncellenir. Ağırlıkların güncelleme işlemi, ÇKA ağırlıklarının öğrenmesi tamamlanıncaya kadar sürdürülür. Başka bir ifade ile eğitim esnasında ağırlıkların ürettiği çıktılar ile beklenen çıktılar arasındaki hatalar kabul edilebilir düzeye ininceye kadar ağırlık güncelleme işlemi sürdürülür.

Geri yayılım algoritmasında ağırlıkların güncelleme işlemi yukarıda ifade ettiğimiz gibi her örnek ağırlığa gösterildikten sonra yapılacağı gibi aynı zamanda eğitim kümesinin bütün örnekleri ağırlığa gösterildikten sonra da yapılabilir [124, 128]. Eğitim kümesinin bütün örnekleri ağırlığa gösterildikten sonra ağırlıkların güncellenmesi işleminde, eğitim kümesindeki bütün örnekler ağırlığa tek tek gösterilir, hatalar hesaplanır ve eğitim kümesindeki örneklerin tamamının hataları toplandıktan sonra bu hata ağırlıklara dağıtılır. Başka bir ifadeyle, ağırlıkların ağırlık değerleri örneklerin tamamı ağırlığa gösterilmedikçe değiştirilmez.

4.3.2. ANFIS

YSA, Bulanık mantık (Fuzzy logic) ve genetik algoritmalar gibi bütün yapay zeka tekniklerinin her birinin kendisine özgü yetenekleri bulunmaktadır. Bu tekniklerden YSA'nın, daha önce de belirtildiği gibi, en önemli yeteneği, problem çözümünde kullanacağı karar verebilme bilgisini örneklerden öğrenme yoluyla elde edebilmesi ve öğrenilen bu karar bilgisi ile daha sonradan kendisine ilk defa gösterilen örnekler için


doğru çözümler üretebilmesidir. Ancak, YSA'nın öğrenme yoluyla elde edilen bu karar bilgisinin kullanıcı tarafından yorumlanamama gibi çok önemli bir dezavantajı mevcuttur. Başka bir ifadeyle YSA, herhangi bir girdi vektörünü çıktı vektörüne nasıl dönüştürdüğü konusunda bir bilgi vermez. Bu özelliğinden dolayı YSA “kara kutu” gibi düşünülebilir [128]. YSA dışında diğer önemli bir yapay zeka tekniği ise Bulanık mantıktır. Bulanık mantık, özellikle kontrol alanındaki başarılı uygulamalarıyla gündeme gelmesine rağmen günümüzde bir çok alanda farklı amaçlar için de kullanılan bir yapay zeka tekniğidir [135]. Bulanık mantık yaklaşımı ile bir problemin çözümünde kullanılacak karar alma bilgisi ilgilenilen problem hakkında bilgi sahibi uzman kişilerce belirlenen kurallardan oluşur. Bu da bulanık mantık yaklaşımli sistemlerin davranışının veya karar sürecinin nasıl gerçekleştiğinin açıklanılabilir olduğunu gösterir. Bulanık mantık yaklaşımının bu özelliği, onu YSA'dan üstün kılan en önemli tarafıdır. Ancak, özellikle problem karmaşıklılığının arttığı durumlar için geliştirilecek bulanık mantık sistemlerinde 2 önemli güçlük karşılaşılr [135]. Bunlardan biri sistem davranışını (karar alma bilgisini) tanımlayan kuralların oluşturulması için standart bir yöntemin olmamasıdır. Çünkü sistem davranışını belirleyen kurallar ilgili problem hakkındaki uzman kişi bilgisine dayandığından bu kurallar kişiden kişiye göre farklılık gösterebilir. Karşılaşılan diğer önemli bir güçlük ise bulanık mantık sistemin girişine ve çıkışına ait uygun üyelik fonksiyonları yapılarının belirlenme güçlüğüdür.

Özellikle 1990'lı yılların başından itibaren YSA ve bulanık mantık tekniklerinin birleşiminden oluşan melez sistemler geliştirilmeye başlandı. Bu melez sistemlerinin geliştirilmesindeki amaç YSA'nın örneklerden öğrenebilme yeteneği ile bulanık mantığın açıklanabilir bilgi ile çalışabilme yeteneğini bir sistemde toplayabilmektir. Geliştirilen bu melez sistemler sinirsel bulanık sistemler (neuro-fuzzy systems) olarak adlandırılmıştır [135]. Bu çalışmada sınıflandırıcı olarak kullanılan ANFIS (Adaptive Neuro-Fuzzy Inference Systems) 1993 yılında Jang tarafından geliştirilmiş bir sinirsel bulanık sistemdir [123]. Burada ANFIS tanıtımının anlaşılabilir olması için öncelikle bulanık mantık ve YSA hakkında genel bilgilerin verilmesi gerekmektedir. YSA hakkındaki genel bilgiler bir önceki alt başlıkta verilmiş olduğundan dolayı burada bulanık mantık hakkında genel bilgiler verildikten sonra ANFIS tanıtımına geçilmiştir.

Bulanık Mantık: İlk olarak 1965 yılında Zadeh tarafından bilim dünyasında gündeme getirilen bulanık mantık kavramı, genel itibarıyla insan düşünce biçimini modellemeye

çalışır. Bulanıklığın, genel olarak kesinlik içermeyen bilgiyi başka bir deyişle belirsizliği ifade ettiği söylenebilir. Bulanık mantık ise, dilsel değişkenler kullanarak kesinlikler yerine belirsizliklerle çalışan bir yapay zeka tekniği olarak tanımlanabilir. Bulanık mantık bu belirsizliklerle çalışabilme özelliği sayesinde klasik matematiksel yöntemler ile modellenmesi güç olan karmaşık sistemlerin modellenmesine olanak sağlar [135]. Bulanık mantık, bulanık küme kuramına dayanmaktadır. Bulanık küme kuramı genel bir matematiksel yaklaşımdır. Bu yaklaşım ile çözülmesi güç olan problemler genel bir yapıya kavuşturularak daha kolay bir sonuca gidilir. Bulanık küme teorisi, bilinen klasik küme kuramının genel halidir. Bulanık mantık kavramında bir üyenin bir kümenin üyesi olup olmadığı üyelik fonksiyonları ile belirlenir.


Bilindiği üzere klasik mantıkta (Boolean Mantığı) bir eleman bir kümenin ya üyesidir (lojik 1) ya da üyesi değildir (lojik 0). Bu tür kümelere keskin (crisp) küme denir. Klasik mantık temeli bu keskin küme kavramına örnek Şekil 4.13’de verilmiştir. Şekilde görüldüğü gibi kişiler boy uzunluğu bakımından 100-160 cm arası için KISA, 160-180 cm arası için ORTA ve 180 cm üstü için ise UZUN olarak tanımlanmıştır. Klasik mantık kuramına göre 159 cm uzunluğundaki bir kişi kısa boylu sayılırken 161 cm boyundaki kişi orta boylu sayılmaktadır. Benzer şekilde 179 cm uzunluğundaki bir kişi Orta boylu iken, 181 cm uzunluğunda olan bir kişide uzun boylu olarak ifade edilir. Oysa gerçek dünyada 159 cm uzunluğunda olan kişi ile 161 cm olan veya 179 cm uzunluğunda olan kişi ile 181 cm olan kişi arasında pek fark olduğu söylenemez. Çünkü gerçek dünyada sınırlar bu kadar keskin değildir. Endüstriyel denetleyici için bu durum ele alınırsa, denetleyicideki fiziksel büyüklüklerin dahil olduğu kümeler birbirinde böyle keskin sınırlarla ayrılmışlarsa denetim çıkışında ani değişiklikler gerçekleşecektir ki bu da istenmeyen bir durumdur.



Şekil 4.13. Boy uzunlukları için klasik kümeler.

Yukarda belirtilmeye çalışılan keskin kümelemekten kaynaklı problemlere, bulanık küme kuramı çok güzel bir çözüm getirmiştir. Nesnelere keskin kümelerin iki seviyeli

(lojik 0, lojik 1) değerler vererek eleman olup olmadığına karar veren işlevine karşılık, $[0,1]$ aralığında değişebilen değerler veren bir işlevi ortaya koyar. Bulanık küme tarafından tanımlanan bu işleve üyelik fonksiyonu denmektedir. Bulanık küme kuramı bu üyelik fonksiyonu işlevi ile nesnelerin kümelere üyeliğine esneklik getirir. Başka bir ifade ile bulanık küme kuramının bu üyelik fonksiyonu işlevi, kısmi (dereceli) üyeliğe izin vererek gerçek dünyayla daha bağdaşır bir mantık sunar [135]. Buna açıklık getirebilmek için yukarda verilen boy uzunluğu kümeleme örneğine bu defa bulanık küme kuramı açısından bakalım. Boy uzunlukları ile ilgili kümeler bulanık kümelerle Şekil 4.14'deki gibi gösterilebilir.



Şekil 4.14. Boy uzunlukları için bulanık kümeler.

Şekil 4.14'de görüldüğü gibi KISA, ORTA ve UZUN bulanık kümeleri sırasıyla yamyuk, üçgen ve yamyuk şeklindeki üyelik fonksiyonları ile temsil edilmiştir. Yine şekilden görüleceği gibi 160–170 cm arası değişken değerleri hem KISA hem de ORTA bulanık kümesine üye iken, 170 -180 cm arası arındaki değişken değerleri ise hem ORTA hem de UZUN bulanık kümesine üyedir. Ancak bu aralıklardaki değerlerin kümeler üye olma seviyeleri aynı derecede değildir. Yani, 160 cm'den 170 cm'ye doğru büyüyen değerler için KISA kümesine üye olma derecesi düşerken, ORTA kümesine üye olma derecesi artmaktadır. Benzer şekilde, 170 cm'den 180 cm'ye doğru büyüyen değerler için ORTA kümesine üye olma derecesi düşerken, UZUN kümesine üye olma derecesi artmaktadır. Dolayısıyla bulanık mantık, boy tanım uzayındaki her değere tanımlanan kümeler içerisinde bir üyelik derecesi vererek gerçek dünya ile daha iyi bağdaşan uygun bir mantık oluşturur.

Bulanık mantık kuramına göre bir bulanık küme, o kümenin elemanları ve elemanların üyelik dereceleri ile gösterilir. Buna göre A bir bulanık küme olmak üzere,

$$A = \{(x, \mu_A(x)) \mid x \in X\} \quad (4.38)$$

şeklinde tanımlanır. Burada; x : A kümesinin bir elemanı, $\mu_A(x)$: değer aralığı $[0,1]$ arasında değişen üyelik fonksiyonu, X : A kümesinin tanımlandığı uzayı gösterir.

Klasik küme kuramında olduğu gibi bulanık küme kuramında da küme işlemleri söz konusudur. Temel bulanık küme işlemlerinin matematiksel tanımlarını verebilmek için A ve B , X uzayında tanımlı iki bulanık küme olarak düşünölsün. Bu kümelerin üyelik fonksiyonları da $\mu_A(x)$ ve $\mu_B(x)$ olarak düşünöldüğünde bulanık kümeler için birleşim (OR), kesişim (AND) ve değil (NOT) işlemleri, aşağıdaki gibi tanımlanır:

Birleşim:

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad (4.39)$$

Kesişim:

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad (4.40)$$

Değil:

$$\mu_{A'}(x) = \{1 - \mu_A(x)\} \quad (4.41)$$

Bulanık kümeleri tanımlayan ve yukarda da verildiğı gibi genelde $\mu(x)$ ile gösterilen üyelik fonksiyonları farklı biçimlerde olabilmektedir. Bunlar arasında uygulamalarda en sık kullanılanları üçgen, yamuk, çan ve gauss biçiminde olan üyelik fonksiyonlardır [136]. Bu fonksiyonlara ait matematiksel ifadeler aşağıda verildiğı gibidir:


$$\text{üçgen}(x; a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right) \quad (4.42)$$

$$\text{yamuk}(x; a, b, c, d) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}\right), 0\right) \quad (4.43)$$

$$\text{çan}(x; a, b, c) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}} \quad (4.44)$$


$$gauss(x; \sigma, c) = e^{\frac{-(x-c)^2}{2\sigma^2}} \quad (4.45)$$

Burada; $\{a, b, c\}$, $\{a, b, c, d\}$ ve $\{\sigma, c\}$ ait oldukları üyelik fonksiyonlarının tanımlama parametreleridir. Yukarıda matematiksel ifadeleri verilen üyelik fonksiyonlarının $x=[0:10]$ aralığındaki şekilsel gösterimleri ise Şekil 4.15’de görülmektedir. Her üyelik fonksiyonunun tanımlama parametreleri için seçilmiş değerler ilgili üyelik fonksiyonun şekilsel gösterimi üzerinde belirtilmiştir.




Şekil 4.15. Çeşitli üyelik fonksiyonları.

Bulanık mantık yaklaşımı, bilgisayarlara insanların özel verilerini işleyebilme ve onların deneyimlerinden ve önsezilerinden yararlanarak çalışabilme yeteneği verir. Bu yeteneği kazandırırken sayısal ifadeler yerine dilsel ifadeler kullanır. Bu dilsel ifadelerin bilgisayarlara aktarılması matematiksel bir temele dayanır. Bu matematiksel temel bulanık küme kuramı ve buna dayanan bulanık mantıktır [135]. Bu yaklaşıma göre tasarlanan bir bulanık sistem ise genelde dört ayrı birimden oluşur. Şekil 2.16’de görüldüğü gibi bunlar; bulandırıcı olarak adlandırılan giriş birimi, kural tabanı, çıkarım mekanizması ve durultucu olarak adlandırılan çıkış birimidir.



Şekil 4.16. Bulanık tabanlı bir sistemin genel yapısı.

1. *Bulandırıcı*: Bulanık sistemin ilk birimi olan bulandırıcı, sisteme girişten gelen keskin değerleri çıkarım mekanizmasında kolayca kullanılabilen dilsel değişkenlere dönüştürür. Başka bir ifade ile bulandırıcı, üyelik fonksiyonundan faydalanarak giriş bilgilerinin ait olduğu bulanık kümeyi/kümeleri ve üyelik derecesini tespit edip, girilen sayısal değere karşılık gelen dilsel değişkenler atar [135]. Buna açıklık getirebilmek için bir endüstriyel denetleyici örneğini göz önüne alalım [137, 138]. Denetleyici giriş değişkenleri hata (e) ve hatadaki değişim (δe) olsun. Bu değişkenlerin bulanık kümeler ile temsili de Şekil 4.17’de verildiği gibi varsayalım.



Şekil 4.17. Giriş değişkenleri için üyelik fonksiyonları: a) hata, b) hatadaki değişim [137].

Şekildeki NB (negatif büyük), NK (negatif küçük), S (sıfır), PK (pozitif küçük), ve PB (pozitif büyük) giriş değişkenlerine ait bulanık küme adlarıdır. Bu kümelerin her biri bir üyelik fonksiyonu ile karakterize edilmiştir. Bulandırıcı işlemine örnek olması açısından e ve δe giriş değişkenlerinin $e=30$ ve $\delta e=-15$ keskin değerlerinin bulandırılması Şekil 4.17’de gösterilmiştir. Bu değerlerin bulandırılması sonucu kendileri için atanan NB, NK, S, PK ve PB dilsel değişkenler ise Tablo 4.2 verilmiştir.


Tablo 4.2. $e=30$ ve $\delta e=-15$ giriş değerleri için bulandırma sonuçları.

Hata ($e=30$)		Hatadaki değişim ($\delta e=-15$)	
Üyelik derecesi	Bulanık küme (Dilsel değişken)	Üyelik derecesi	Bulanık küme (Dilsel değişken)
0.7	S	0.5	NB
0.3	PK	0.5	NK
0	NB, NK, PB	0	SI, PK, PB

2. *Kural tabanı:* Bir bulanık sistemin kural tabanı, genellikle ilgilenilen sistem hakkında bilgi sahibi uzman kişilerin dilsel tanımlamalarından elde edilen bir grup IF-THEN kuralından oluşur. Bu kurallar ile ilgilenilen sistemin giriş ve çıkış ilişkisi dilsel olarak ifade edilir. Dolayısıyla bir anlamda bu kural tabanı bulanık mantık yaklaşımlı sistemin dinamik davranışının söz dizesel karşılığı olmaktadır. Kural tabanı birimini anlaşılır kılmak için daha önce verilen endüstriyel bulanık denetleyici örneğini tekrar göz önüne alalım. Bu denetleyici örneğinin giriş değişkenleri için tanımlanan üyelik fonksiyonları Şekil 4.17’de verilmişti. Çıkış değişkeni (u) için tanımlanan üyelik fonksiyonları da Şekil 4.18’deki gibi olsun. Denetleyicinin denetleme mekanizmasını belirleyen ve uzman kişinin bilgi ve tecrübesi ile oluşturulduğu varsayılan kural tabanı ise Tablo 4.3 verildiği gibi olsun. Bu tabloya göre örnek bir kural aşağıda verildiği gibi yazılabilir:

IF (e is PK AND δe is NB) THEN (u is NK)

Örnek kuraldan da görüldüğü üzere dilsel kuralların genel ifade biçimi; IF (Varsayım) THEN (Sonuç) şeklindedir. Kuralların “Varsayım” kısmı bulanık sistemin giriş değişkenleri ile “Sonuç” kısmı ise çıkış değişkeni ile ilişkilidir. Yine örnek kuraldan görüldüğü gibi, her varsayım AND işlemi ile bağlanmış iki terimden oluşmaktadır. Bununla birlikte varsayım kısmı ikiden fazla terimden oluşabileceği gibi OR ve NOT işlemleri ile de bağlanabilir. Eğer sistemin çıkışı birden fazla ise kuralları sonuç kısmı da birden fazla terim içerebilir.



Şekil 4.18. Çıkış değişkeni için üyelik fonksiyonları [137].

Tablo 4.3. Kural tabanı [137].
 δ_e

u	δ_e				
	NB	NK	S	PK	PB
NB	NB	NB	NO	NK	S
NK	NB	NO	NK	S	PK
S	NO	NK	S	PK	PO
PK	NK	S	PK	PO	PB
PB	S	PK	PO	PB	PB

3. *Çıkarım mekanizması*: Çıkarım mekanizması, bulandırıcı çıkışlarını ve kural tabanını kullanarak bir bulanık küme oluşturur. Çıkarım mekanizmalarında iki ana yaklaşım söz konusudur Bunlardan ilki “ birleşim esaslı çıkarım “ diğeri ise “bireysel kural esaslı” çıkarımdır. Birleşim esaslı çıkarım yaklaşımında, öncelikle bütün kurallar birleştirilerek tek bir bulanık bağıntı elde edilir. Sonra, bu bağıntı ve bulandırıcı biriminden gelen sonuçlar kullanılarak çıkarım gerçekleştirilir. Böylece bulanık sistemin çıkışını tanımlayan bir bulanık küme elde edilmiş olur. Bireysel kural esaslı çıkarım yaklaşımında ise, her kural bireysel bir bulanık çıkış kümesi belirler ve çıkarım mekanizmasının çıkışı bireysel bulanık çıkış kümelerinin toparlanması ile elde edilir. Bireysel kural esaslı çıkarım mekanizmasının hesaplama süresi açısından daha avantajlı olması onu kullanımda daha tercih edilir bir yaklaşım haline getirir. Çıkarım mekanizmasında, dikkate alınması gereken üç ana işlem türü vardır; İlki kuralların varsayım kısmındaki terimler arasındaki işlemlerdir. Bilindiği üzere bu işlemler AND, OR ve NOT gibi işlemlerdir. Bu işlemler esas itibarıyla giriş değerlerinin üyelik dereceleri arasındaki işlemleri gerçekleştirirler ve sonuç olarak her kural için kuralın kesinlik derecesi elde edilir. İkinci ana işlem ise kuralın kesinlik derecesi ile ilgili kuralın bulanık çıkış kümesi arasındaki “ima” işlemidir. Bu

işlemden sonra kural tabanındaki her kural bir ima edilen bulanık çıkış kümesi oluşturur. Üçüncü ana işlem ise, sonuç bulanık çıkış kümesini elde etmek için tüm ima edilmiş çıkış bulanık kümelerini toplama işlemidir [137,138]

4. Durultucu: Durultucu birimi, çıkarım mekanizması biriminden gelen sonuç çıkış bulanık kümesini kullanarak sistemin bulanık olmayan keskin çıkış değerini hesaplar. Durultma işlemi için değişik yöntemler kullanılmaktadır. Bunlar arasında en sık kullanılanları; maksimum üyelik yöntemi, ağırlık merkezi yöntemi, ağırlık ortalaması yöntemi ve mean-max üyelik yöntemidir [135].

Yukarıda genel hatlarıyla anlatılan bulanık sistem genelde MAMDANI tipi bulanık sistem olarak bilinir. Çok sık kullanılan diğer bir bulanık sistem türü de Takagi-Sugeno tipi bulanık sistemdir. Bu sistemi MAMDANI tipi bulanık sistemden ayıran en önemli fark kurallarda gösterilen çıkışların bulanık kümelerle değil de giriş değişkenlerinin fonksiyonları şeklinde ifade edilmesidir. Takagi-Sugeno tipi bir bulanık sistemde kuralların ifade ediliş biçimi aşağıda verildiği gibidir;

IF (x_1 is A_1 AND x_2 is A_2) THEN $y=f(x_1,x_2)$

Burada $f(.)$ giriş değişkenlerinin doğrusal veya doğrusal olmayan bir fonksiyonudur. Verilen kuraldan da anlaşılacağı gibi çıkış doğrudan bir fonksiyonla belirlendiğinden bu tip bulanık sistemde ‘durultucu’ birimine ihtiyaç bulunmamaktadır [137].

ANFIS: Daha öncede ifade edildiği üzere sinirsel bulanık sistemler (neuro-fuzzy systems), yapay sinir ağlarının öğrenme yeteneği ve bulanık mantığın insan gibi karar verme ve uzman bilgisi sağlama kolaylığı gibi üstünlüklerinin birleştirilmesi fikrine dayalı olarak geliştirilen melez sistemlerdir [135]. Bu tür melez sistemler ile bulanık mantık çıkarım sistemlerine YSA’nın öğrenme ve hesaplama yeteneği kazandırılırken, YSA sistemlerine de bulanık mantık çıkarım sistemlerinin insan gibi karar verme ve uzman bilgisi sağlama yeteneği kazandırılır.

Yukarıda ifade edilen sinirsel bulanık sistemlerin bir modeli 1993 yılında Jang tarafından ortaya atılmış olan ANFIS modelidir [123]. Bu model, insan gibi karar verme ve uzman bilgisi sağlama yeteneği için Takagi-Sugeno bulanık mantık çıkarım sistemini temel


alırken, üyelik fonksiyonlarını tanımlayan parametrelerin ayarlanması/uyarlanması (öğrenme yeteneği) için de YSA'nın geri yayılım öğrenme algoritmasını kullanır.

ANFIS modelinin tanıtımını yapabilmek için birinci dereceden SUGENO bulanık siteme göre belirlenmiş iki IF-THEN kuralı aşağıda verildiği gibi olsun;

Kural 1: IF (x is A_1 AND y is B_1) THEN ($f_1=p_1x+q_1y+r_1$)

Kural 2: IF (x is A_2 AND y is B_2) THEN ($f_2=p_2x+q_2y+r_2$)

Burada; x ve y girişleri, A_i ve B_i girişlere ait bulanık kümeleri ve f_i kuralların sonuç kısmını temsil eden doğrusal fonksiyonları gösterirler. Bu tanımlamalara göre x ve y gibi iki girişten, f gibi tek çıkıştan ve iki kuraldan oluşan bir ANFIS yapısı Şekil 4.19'de gösterildiği gibi olmaktadır:



Şekil 4.19. İki girişli ve iki kurallı ANFIS yapısı.

Her katmana ait düğüm işlevleri ve katmanların işleyişi ise sırasıyla şöyledir:

1.Katman: Bu katman bulandırıcı katmandır. Bu katmandaki her bir düğüm uyarlanabilir bir bulanık küme ile ifade edilir. Her düğümün çıkışı, düğüme gelen giriş değerlerine ve düğüme ait üyelik fonksiyonuna göre belirlenen üyelik dereceleri olmaktadır. Buna göre düğüm çıkışları,

$$\begin{aligned} O_i^1 &= \mu_{A_i}(x) \\ O_{i+2}^1 &= \mu_{B_i}(y) \end{aligned} \quad i=1,2 \text{ için} \quad (4.46)$$

biçiminde olmaktadır. Eğer her düğüme ait üyelik fonksiyonu için (4.45) bağıntısı ile tanımlanan gauss üyelik fonksiyonu kullanılırsa düğüm çıkışları,

$$\begin{aligned} O_i^1 &= \mu_{A_i}(x) = e^{-\frac{(x-c_i)^2}{2\sigma_i}} \\ O_{i+2}^1 &= \mu_{B_i}(y) = e^{-\frac{(y-c_{i+2})^2}{2\sigma_{i+2}}} \end{aligned} \quad i=1,2 \quad (4.47)$$

biçiminde daha açık bir şekilde ifade edilmiş olunur. Burada σ ve c gauss üyelik fonksiyonun tanımlama parametreleridir. σ gauss üyelik fonksiyonunun genişlik tanımlama parametresi iken, c ise gauss üyelik fonksiyonunun merkez tanımlama parametresidir. Bu katmandaki düğümlerin uyarlanabilir bulanık kümelerden oluştuğu ile kast edilmek istenen bu parametrelerin öğrenme yoluyla ayarlanabilir olduğudur. Bu katmanda 4 düğüm söz konusu olduğundan ve her düğümün gauss üyelik fonksiyonu da iki parametre ile tanımlandığına göre bu katmanda ayarlanması gereken parametre sayısı 8 tanedir. Bu katmandaki bu ayarlanabilir parametreler öncül parametreler (premise parameters) olarak adlandırılır.

2.Katman: Bu katmanın düğümleri sabit düğümlerden oluşur. Bu katmandaki düğüm sayısı aynı zamanda kural sayısının da belirler. Bu katmanda her kuralın kesinlik derecesi cebirsel çarpım kullanılarak hesaplanır. Her kuralın kesinlik derecesi veya başka bir ifadeyle her düğümün çıkışı,

$$O_i^2 = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i=1,2 \quad (4.48)$$

şeklinde hesaplanır.

3.Katman: Bu katmandaki her bir düğüm, kural katmanından gelen tüm düğümleri giriş değeri olarak kabul etmekte ve bu katmanda her bir kuralın normalize edilmiş ateşleme seviyesi,

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (4.49)$$

şeklinde hesaplanır.

4.Katman: Bu katmandaki düğümler uyarlanabilir düğümlerdir. Bu katmanda normalize edilmiş her bir kural kendine ait çıkış fonksiyonu ile çarpılır.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (4.50)$$

Burada $\{p_i, q_i, r_i\}$, bu katmanda bulunan düğümlerin parametrelerinden oluşan, parametre kümesidir. Bu parametreler sonuç parametreleri (consequent parameters) olarak adlandırılır. Bu parametreler de 1. katmandaki öncül parametreler gibi öğrenme yoluyla ayarlanabilen parametrelerdir. Bu ANFIS yapısında 2 kural söz konusu olduğundan bu katmanın ayarlanabilen sonuç parametrelerinin sayısı 6 tanedir.

5.Katman: Son katman olan bu katman ile 4. katmandaki her bir düğümün çıkış değerleri toplanır ve sonuçta ANFIS sisteminin gerçek çıkış değeri elde edilmiş olunur.

$$O_i^5 = f = \sum_{i=1}^2 \bar{w}_i f_i = \sum_{i=1}^2 \left[\left(\frac{w_i}{w_1 + w_2} \right) (p_i x + q_i y + r_i) \right] \quad (4.51)$$

ANFIS öğrenme algoritması olarak genelde melez bir öğrenme algoritması kullanır. Bu algoritma geri yayılım algoritması ile en küçük kareler yönteminin birleşiminden oluşur. En küçük kareler yöntemi ile 4. katmanda tanımlanan sonuç parametrelerinin değerleri ayarlanırken, Geri yayılım algoritmasıyla da 2.katmandaki öncül parametrelerinin değerleri ayarlanır [123].

4.3.3. Destek Vektör Makineleri

DVM, sınıflandırma ve doğrusal olmayan fonksiyon yaklaşımı problemlerinin çözümü için, ilk olarak Vapnik tarafından ortaya atılan [139, 140] ve sonradan diğer bilim adamlarınca da geliştirilen [126, 141, 142], oldukça yeni bir yöntemdir [143]. DVM istatistiksel öğrenme teorisi çatısı altında geliştirilir ve örüntü tanıma, fonksiyon tahmini, zaman serileri tahmini, mühendislik ile biyoloji gibi birçok alana başarıyla uygulanmaktadır. DVM başlıca üç bileşenden oluşmaktadır. Bunlar; istatistiksel öğrenme teorisi, optimizasyon algoritması ve çekirdek fonksiyonlarıdır. Bu bağlamda, DVM çekirdek fonksiyonlarıyla dönüştürülmüş olan nitelik uzayında iyi bir genelleme teorisinin ışığında ve optimizasyon teorisinin yardımıyla doğrusal olarak eğitilen bir öğrenme makinesi olarak tanımlanabilir [144]. DVM bir sınıflandırıcı olarak başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmıştır. Daha sonra matematiksel alt yapısı güçlendirilerek doğrusal olmayan verilerin ve çok sınıflı verilerin sınıflandırılması problemlerinin çözümü için genelleştirilmiştir.

DVM yapısal olarak, düşük boyutlu bir giriş uzayından alınan veri örneklerini, yüksek boyutlu bir diğer uzaya doğrusal olmayan bir biçimde taşıyan bir dönüşümdür. Dönüşümü gerçekleyen makine, sistem ya da ağ, dönüşümü belirleyen bir çekirdek ile tanımlanır. Sınıflama problemlerinde, yeteri kadar yüksek boyutlu uzaya taşınan veriler doğrusal ayrıştırılabilir duruma gelir. En uygun doğrusal ayrıştırıcı düzlem, ayrıştıran düzlemler arasından sınıflara eşit ve maksimum mesafede olanıdır. Sınır (margin) olarak adlandırılan bu maksimum mesafe veya uzaklık; sınıflara ait veri örnekleri arasından ayrıştırıcı düzleme en yakın olan örneklerden belirlenir. Belirlenen örnekler *Destek Vektörler* olarak adlandırılır [145].

Verilerden veya örneklerden öğrenebilen YSA gibi geleneksel öğrenme makinelerinin sınıflandırma amaçlı kullanıldığı birçok alanda başarılı sonuçları olmakla birlikte, bu yöntemlerin bazı önemli eksiklikleri mevcuttur. Bu eksikliklerin başında, yeterince eğitim verisine sahip olma ihtiyacı, düşük yakınsama oranı, yerel minimuma takılma problemi ve ezberleme problemleri gelmektedir [144, 146]. Bu problemlerin çoğu geleneksel yöntemlerin deneysel risk minimizasyonuna bağlı olarak eğitilmesinden kaynaklanır. Oysa DVM, deneysel riskin yanında yapısal riski de minimize edecek biçimde eğitilir. DVM bu özelliği ile geleneksel yöntemlerde mevcut olan problemlerin birçoğunu aşarak, genelleme yeteneği yüksek olan, az miktarda eğitim verisiyle

öğrenebilen ve yerel minimumlar yerine global minimumlara ulaşabilen sınıflandırıcıların tasarımına imkan sağlar.

Sınıflandırıcı olarak DVM, karşılaşılan verinin karmaşıklık durumuna bağlı olarak üç ayrı biçimde incelenebilir. Bunlar; doğrusal olarak ayrılabilen veriler için DVM sınıflandırıcısı, doğrusal olarak belirli bir hata ile ayrılabilen veriler için DVM sınıflandırıcısı ve doğrusal olmayan veriler için DVM sınıflandırıcısı olarak tarif edilir.

a) Doğrusal olarak ayrılabilen veriler için DVM sınıflandırıcısı

Eğitim için kullanılacak iki sınıflı k sayıda örnekten oluşan bir veri kümesi $\{x_i, y_i\}, i=1,2,\dots,k$, şeklinde tanımlansın. Burada $x_i \in R^d$ olup d -boyutlu özellik vektörünü, $y_i \in \{-1,+1\}$ ise sınıflara ait etiket değerlerini temsil eder. Doğrusal olarak ayrılabilme durumunda, bu tanımlanmış olan iki sınıflı eğitim veri kümesi bir ayırıcı düzlem ile doğrudan ayrılacaktır. Ancak, bu iki sınıflı eğitim kümesini ayırabilen sonsuz sayıda ayırıcı düzlem söz konusudur. DVM sınıflandırıcı algoritmasının amacı, olası ayırıcı düzlemler arasından veriyi -1 ve $+1$ ile etiketlenen sınıflara ayırabilecek en uygun (optimal) ayırıcı düzlemi belirlemektir. Ayırıcı düzlem üzerindeki herhangi bir x noktası, w ayırıcı düzlemin normali ve $|b|/\|w\|$ ayırıcı düzlemin orijine dik uzaklığı varsayıldığında, DVM algoritması

$$f(x) = w^T \cdot x + b = 0 \quad (4.52)$$

İle tanımlanan en uygun ayırıcı düzlemi bulmaya çalışır. Bunun için eğitim veri kümesinin aşağıda belirtilen bağıntıları sağlaması gerekmektedir:


$$w^T \cdot x_i + b \geq +1, \quad y_i = +1 \text{ için} \quad (4.53)$$

$$w^T \cdot x_i + b \leq -1, \quad y_i = -1 \text{ için} \quad (4.54)$$

Bu iki eşitsizlik tek bir eşitsizlik olarak ifade edildiğinde,

$$y_i(w^T \cdot x_i + b) - 1 \geq 0 \quad (4.55)$$

elde edilir. Verilen eğitim verisi kümesi için olası tüm ayırıcı düzlemler bu son eşitsizlik ile temsil edilebilir. Burada en uygun ayırıcı düzlemin belirlenmesi için bu ayırıcı düzlemi karşılayacak uygun w ve b değerleri hesaplanmalıdır. Doğrusal ayrılabilirlik durumuna ilişkin temsili gösterim Şekil 4.20’de verilmiştir.



Şekil 4.20. Doğrusal olarak ayrılabilen veri kümesi için DVM sınıflandırıcısı.

(4.53)’deki bağıntının eşitlik durumu ($w^T x_i + b = +1$) Şekil 4.20’deki S_2 sınıfını ayıran A_2 ayırıcı düzleme, (4.54)’deki bağıntının eşitlik durumu ($w^T x_i + b = -1$) ise Şekil 4.20’deki S_1 sınıfını ayıran A_1 ayırıcı düzlemine karşılık geldiği varsayılırsa; A_1 düzleminin orijine dik uzaklığı $|1 - b|/\|w\|$ ve A_2 düzleminin orijine dik uzaklığı $|-1 - b|/\|w\|$ olacaktır. A_1 ve A_2 ayırıcı düzlemlerin en uygun ayırıcı düzleme ($w^T x_i + b = 0$) uzaklıkları ise $1/\|w\|$ olacaktır. Bu iki ayırıcı düzlem veya başka bir deyişle eğitim kümesine ait iki veri kümesi arasındaki uzaklık $2/\|w\|$ olur. Burada A_1 ve A_2 ayırıcı düzlemlerin aynı normale sahip olduklarına (paralel olduklarına) ve bu düzlemler arasında eğitim veri kümesine ait hiçbir örnek bulunmadığına dikkat edilmelidir. İki ayırıcı düzlem arasındaki uzaklık ($2/\|w\|$) sınır

(margin) olarak adlandırılır. DVM algoritmasıyla yapılmaya çalışılan, bu sınırı maksimize etmektir. Dolayısıyla $\|w\|$ 'nin minimum olmasını sağlamaktır. Aralarındaki sınır maksimum olan ayırıcı düzlemlerin üzerinde yer alan veri örnekleri ise *Destek Vektörleri* olarak adlandırılır [147].

Maksimum sınırın bulunması işlemi;

$$\text{Minimizasyon } f = \frac{1}{2} \|w\|^2 = \frac{w^T \cdot w}{2} \quad (4.56)$$

$$\text{Kısıtlama: } y_i(w \cdot x_i + b) - 1 \geq 0, \quad i = 1, 2, \dots, k \quad (4.57)$$

ile ifade edilir. Burada; (4.56)'daki eşitlik ifadesi çözülecek problemi, (4.57)'deki eşitsizlik ifadesi ise bu problemin hangi kısıtlama (koşul) altında çözüleceğini gösterir. Ayrıca, bu ifadeler problemin ikinci dereceden bir optimizasyon problemi olduğunu gösterir. Bu optimizasyon problemi, ikinci dereceden programlama tekniğinin kullanılmasıyla çözülebilir. Ancak, çok yüksek boyutlu uzaylar için problemin şu anki formda çözülebilmesi pratik olmamaktadır. Bu nedenle problem pratik olarak çözülebileceği ikincil (dual) forma dönüştürülür [144]. Problemin ikincil forma dönüştürülmesi iki adımda gerçekleştirilir.

İlk adımda; Lagrange çarpanları yöntemi kullanılarak, (4.56) eşitlik ifadesi ile gösterilen kısıtlamalı optimizasyon problemi, (4.58) eşitlik ifadesi ile gösterilen kısıtlamasız optimizasyon problemi biçiminde tekrar yazılır.

$$\begin{aligned} L(w, b, \alpha) &= \frac{w^T \cdot w}{2} - \sum_{i=1}^k \alpha_i [y_i(w^T \cdot x_i + b) - 1] \\ &= \frac{w^T \cdot w}{2} - \sum_{i=1}^k \alpha_i y_i w^T \cdot x_i - \sum_{i=1}^k \alpha_i y_i b + \sum_{i=1}^k \alpha_i \end{aligned} \quad (4.58)$$

Buradaki $\alpha_i \geq 0$ değerleri Lagrange çarpanları olarak adlandırılır.

İkinci adımda ise (4.58) eşitliğini sadece α_i Lagrange çarpanlarına bağlı olarak optimize edilebilecek bir ikincil problem formuna dönüştürmek için Karush-Kuhn-Tucker koşullarını kullanılır. Karush Kuhn-Tucker teoremine göre (4.58) eşitliğinin aşağıda belirtilen şartları sağlaması gerekir;

$$\frac{\partial L}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^k \alpha_i x_i y_i \quad (4.59)$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^k x_i y_i = 0 \quad (4.60)$$

Bu koşullar (4.58)'deki eşitlik ifadesinde yerine yazılacak olursa, optimizasyon probleminin ikincil problem formuna dönüşmüş biçimi:

$$\text{Maksimizasyon} \quad L_{ikincil}(\alpha) = -\frac{1}{2} \sum_{i,j=1}^k \alpha_i \alpha_j y_i y_j x_i \cdot x_j + \sum_{i=1}^k \alpha_i \quad (4.61)$$


$$\text{Kısıtlamalar:} \quad \sum_{i=1}^k \alpha_i y_i = 0 \quad \alpha_i \geq 0, \quad i = 1, 2, \dots, k \quad (4.62)$$

olarak elde edilir. Elde edilen bu ikincil optimizasyon problemi verilen kısıtlamalar altında karesel (ikinci dereceden) programlama yöntemleri kullanılarak çözülür. Bu problemin çözümü ile α_i değerleri bulunur. w ise (4.59)'daki eşitlikten elde edilir. Burada dikkat edilirse, eğitim kümesinin her örneği için bir tane Lagrange çarpanı bulunmaktadır. Lagrange çarpanı pozitif değerli olan eğitim kümesi örnekleri (x_i) *Destek Vektörleri* olarak isimlendirilirler ve A_1 veya A_2 ayırıcı düzlemlerin üzerinde yer alırlar. Lagrange çarpanı sıfır değerlikli olan diğer eğitim kümesi örnekleri ise A_1 ve A_2 ayırıcı düzlemlerinin arka tarafında kalan örneklerdir [147].

b) Doğrusal olarak belirli bir hata ile ayrılabilen veriler için DVM sınıflandırıcısı

Eğitim kümesine ait veriler doğrusal olarak tamamen ayrılabilir durumda değilse verileri minimum sayıda hata ile sınıflandırabilecek bir çözüm algoritması kullanılır. Bu algoritma, bir önceki alt başlık altında verilmiş olan doğrusal olarak ayrılabilir verilerin sınıflandırması probleminin çözümü için kullanılan algoritmanın daha genelleştirilmiş bir biçimidir [140].

Doğrusal olarak tamamen ayrılamayan verilerin sınıflandırılması probleminin Şekil 4.21'den de görüleceği üzere pozitif değerler alan ve sınıflandırma hatalarını ifade eden gevşek değişkenlerin (ξ_i) tanımlanması ve optimizasyon modeline eklenmesi ile çözülür [140]. Tanımlanacak $\xi_i \geq 0$ gevşek değişkeni, eğitim kümesine ait herhangi bir örneğin ait olması gereken sınıfın sınırından olan sapma miktarıdır. Dolayısıyla eğitim kümesine ait herhangi bir örneğin doğru veya yanlış sınıflandırılmış olması o örneğin ξ_i gevşek değeri ile ilişkilidir. Eğer eğitim kümesine ait herhangi bir örneğin ξ_i değeri, 0 ise o örnek doğru sınıflandırılmış, 0-1 aralığında ise o örnek doğru sınıflandırılmış ancak belirlenmiş olan maksimum sınır aralığında yer alıyor, 1 ve 1'den büyük ise yanlış sınıflandırılmıştır demektir. Bu durumun temsili gösterimi Şekil 4.21'de verilmiştir.



Şekil 4.21. Doğrusal olarak belirli bir hata ile ayrılabilen veri kümesi için DVM sınıflandırıcısı.

Yukarıda belirtilen ifadeler doğrultusunda doğrusal olarak tamamen ayrılabilen verilerin eşitlik (4.54) ve eşitsizlik (4.55) ile tanımlan optimizasyon problemi ξ_i gevşek değişkenleri dikkate alınarak yeniden düzenlenecek olursa;

$$\text{Minimizasyon} \quad f = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^k \xi_i \quad (4.63)$$

$$\text{Kısıtlamalar:} \quad y_i (w \cdot x_i + b) - 1 + \xi_i \geq 0 \quad (4.64)$$

$$\xi_i \geq 0 \quad i = 1, \dots, k \quad (4.65)$$

şeklinde doğrusal olarak tamamen ayrılamayan veriler için optimizasyon problemi tanımlanmış olur. Eşitlik (4.63)'ün ikinci bileşeninin $\sum_i^k \xi_i$ çarpanı yanlış sınıflandırma hataları sayısının üst sınırın belirtir. Eşitlik (4.63)'ün ikinci bileşeninin C çarpanı ise sınırın maksimum hale getirilmesi ve yanlış sınıflandırma hataları sayısının minimum hale getirilmesi arasındaki dengenin sağlanması işlevini gören sabit bir parametredir. C parametresi dengeleyici işlevi dolayısıyla düzenleyici parametre olarak adlandırılır. Bu parametrenin değeri kullanıcı tarafından belirlenir. Eğer optimizasyon problemi yüksek boyutlu uzayda çözülüyorsa ikincil formuna dönüştürülmelidir. Bu safhada yapılması gereken işlemler bir önceki alt başlık altında verilen doğrusal ayrılabilir durumdaki veriler üzerinde gerçekleştirilen işlemlerle aynıdır. Bu işlemlerin burada da tekrarlanması ile optimizasyon probleminin ikincil formu;


$$\text{Maksimizasyon} \quad L_{ikincil}(\alpha_i) = \sum_{i=1}^k \alpha_i - \frac{1}{2} \sum_{i,j=1}^k \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (4.66)$$

$$\text{Kısıtlamalar:} \quad \sum_{i=1}^k \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, k \quad (4.67)$$

biçiminde olur. Bu problem ikinci dereceden (karesel) programlama teknikleri kullanılarak doğrusal olarak ayrılamayan veriler için en uygun DVM sınıflandırıcı parametreleri belirlenir. Burada, $0 < \alpha_i < C$ aralığındaki Lagrange çarpanlarına karşılık gelen x_i örnekleri DVM sınıflandırıcısının destek vektörlerini temsil eder.

c) Doğrusal olmayan veriler için DVM sınıflandırıcısı

Doğrusal olarak tamamen veya belirli bir hata ile ayrılabilen verilerin sınıflandırılması probleminin çözümü için geliştirilen DVM algoritmalarının pratik uygulamaları oldukça kısıtlıdır. Çünkü gerçekte karşılaşılan veri kümelerinin giriş uzayındaki dağılımı Şekil 4.22’de görüleceği gibi doğrusal olmadığından bu verileri bulundukları asıl uzayda doğrusal bir ayırıcı düzleme ile ayırtırmak pek mümkün olmamaktadır.



Şekil 4.22. Giriş uzayını yüksek boyutlu özellik uzayına haritalama [148].

Bulundukları asıl uzayda doğrusal olarak ayrıştırılamayan bu veriler bir çekirdek fonksiyonu yardımıyla yüksek boyutlu bir özellik uzayına taşınarak, o uzayda doğrusal olarak ayrıştırılabilir [139, 145]. Böylece yüksek boyutlu özellik uzayındaki çok boyutlu ayırıcı düzlem, asıl uzayda doğrusal olmayan bir işleve karşılık gelir.

Eğitim kümesine ait d boyutlu örnekleri bulundukları giriş uzayından daha yüksek boyutlu H Euclid uzayına (özellik uzayına) dönüştüren Φ fonksiyonun olduğu düşünülür.

$$\Phi : R^d \mapsto H \quad (68)$$

Bu durumda DVM’nin eğitim algoritması H uzayındaki verilerin $\Phi(x_i) \cdot \Phi(x_j)$ iç çarpımına bağlı olacaktır. Ancak yüksek boyutlu H özellik uzayındaki bu iç çarpımın hesaplanması güç olacağından bunun yerine düşük boyutlu giriş uzayında, çekirdek fonksiyonları kullanılarak bu işlem gerçekleştirilir. Kernel fonksiyonları olarak da adlandırılan ve K ile gösterilen bu çekirdek fonksiyonlarının genel ifadesi,

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (69)$$

şeklindedir. Verinin yüksek boyutlu uzaya dönüşümü ve problemin çözümü için kullanılan bu çekirdek fonksiyonları belirlenirken Mercer teoreminde belirtilen koşulları sağlaması gerekmektedir [147]. Yaygın olarak kullanılan çekirdek fonksiyonlarının bazıları Tablo 4.4’de verilmiştir. Doğru çekirdek fonksiyonunun seçimi sınıflandırma işleminin performansını etkileyen en önemli faktörlerden biridir. Literatürde en yaygın kullanılan çekirdek fonksiyonunun radyal tabanlı çekirdek fonksiyonu olduğu ve bu fonksiyon ile yüksek sınıflandırma başarımının elde edildiği ifade edilmektedir [141, 149, 150].

Tablo 4.4. Yaygın olarak kullanılan çekirdek fonksiyonları.

Çekirdek fonksiyonu	Matematiksel formulu	Parametreler
Doğrusal	$K(x_i, x_j) = x_i \cdot x_j$	-
Polinomal	$K(x_i, x_j) = (x_i \cdot x_j + 1)^d$	d , fonksiyonun derecesi
Radyal tabanlı	$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right)$	σ , fonksiyonun Genişlik parametresi

Eşitlik (4.66)’daki $x_i \cdot x_j$ iç çarpan yerine bununu yüksek boyutlu özellik uzaydaki karşılığı olan $K(x_i, x_j)$ çekirdek fonksiyonu ile yer değiştirirse, doğrusal olmayan verileri yüksek boyutlu özellik uzayında ayırabilen ayrıştırıcı düzlemin belirlenmesine,

$$\text{Minimizasyon } L_{ikincil}(\alpha_i) = \sum_{i=1}^k \alpha_i - \frac{1}{2} \sum_{i,j=1}^k \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (70)$$

$$\text{Kısıtlamalar: } \sum_{i=1}^k \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C \quad i = 1, \dots, k \quad (71)$$

biçiminde ifade edilen optimizasyon probleminin çözümü ile ulaşılır. Bu problem ikinci dereceden (karesel) programlama teknikleri kullanılarak çözülür.

4.3.4. En küçük Kareler Destek Vektör Makineleri

Bir önceki başlık altında tanıtılan DVM standart DVM olarak bilinmektedir. Standart DVM doğrusal olarak sınıflandırılmayan giriş veri kümesini çekirdek fonksiyonları yardımıyla yüksek boyutlu bir özellik uzayına taşır. Daha sonra bu uzay içerisinde giriş verilerini birbirinden ayıracak en uygun ayırıcı düzlem belirlenir. Bu ayırıcı düzleme bir karesel programlama probleminin çözümü ile ulaşılır. Bu tez çalışmasında standart DVM sınıflandırıcısı yerine bunun yeniden düzenlenen bir versiyonu olan en EKK-DVM kullanılmıştır. EKK-DVM, [Suykens ve Vandewalle \(1999\)](#) tarafından önerilmiştir [\[151\]](#). Bu DVM çeşidini standart DVM sınıflandırıcısından farklı kılan en önemli özelliği en uygun ayırıcı düzlem belirlenirken karesel programlama problemi yerine bir doğrusal denklem seti kullanılmasıdır. Böylece sınıflandırıcının hesaplama yükü önemli ölçüde azaltılmış olur.

EKK-DVM sınıflandırıcısı ile maksimum sınır veya en uygun ayırıcı düzlemin belirlenmesi problemi,

$$\text{Minimizasyon} \quad J(w, b, \xi) = \frac{1}{2} \|w\|^2 + \frac{C}{2} \sum_{i=1}^k \xi_i^2 \quad (4.72)$$

$$\text{Kısıtlamalar:} \quad y_i [w \cdot \Phi(x_i) + b] = 1 - \xi_i \quad i = 1, 2, \dots, k \quad (4.73)$$

biçiminde formüle edilir. Burada dikkat edileceği üzere EKK-DVM standart DVM’de kullanılan eşitsizlik kısıtlamaları yerine Eşitlik (4.73) ile ifade edilen eşitlik kısıtlamalarını kullanır. Problemin lagrange formülasyonu ise,

$$L(w, b, \xi; \alpha) = J(w, b, \xi) - \sum_{i=1}^k \alpha_i \{y_i [w \cdot \Phi(x_i) + b] - 1 + \xi_i\} \quad (4.74)$$

biçimindedir. Burada α_i lagrange çarpanları olup pozitif veya negatif değerler alabilmektedir. Oysa standart DVM sınıflandırıcılarında bu çarpanlar sadece pozitif

değerler alabilmektedir. Problemin optimal çözümü için sağlaması gereken koşullar aşağıda verildiği gibidir [151].

$$\begin{aligned}
\frac{\partial L}{\partial w} = 0 &\rightarrow w = \sum_{i=1}^k \alpha_i y_i \Phi(x_i), \\
\frac{\partial L}{\partial b} = 0 &\rightarrow \sum_{i=1}^k \alpha_i y_i = 0, \\
\frac{\partial L}{\partial \xi_i} = 0 &\rightarrow \alpha_i = C \xi_i, \\
\frac{\partial L}{\partial \alpha_i} = 0 &\rightarrow y_i [w \cdot \Phi(x_i) + b] - 1 + \xi_i = 0
\end{aligned} \tag{4.75}$$

Eşitlik (4.74) ile ifade edilen problemin optimal çözümü için gereken bu koşullar kullanılarak aşağıda verilen doğrusal denklem elde edilir.

$$\left[\begin{array}{c|c} 0 & -Y^T \\ \hline Y & ZZ^T + C^{-1}I \end{array} \right] \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \bar{1} \end{bmatrix} \tag{4.76}$$

Burada $Z = [\Phi(x_1)^T y_1; \dots; \Phi(x_k)^T y_k]$, $Y = [y_1; \dots; y_k]$, $\bar{1} = [1; \dots; 1]$ ve $\alpha = [\alpha_1; \dots; \alpha_k]$. EKK-DVM sınıflandırıcılarında karar mekanizmasını belirlemek için gerekli α ve b parametreleri Eşitlik (4.76) ifade edilen doğrusal denklemin çözümünden elde edilir. Bu parametrelerin bulunması ile EKK-DVM sınıflandırıcısı için oluşturulmak istenen karar mekanizması aşağıda verildiği gibi ifade edilmiş olur.

$$f(x) = \text{sign} \left[\sum_{i=1}^k \alpha_i y_i K(x, x_i) + b \right] \tag{4.77}$$

Burada $K(x, x_i)$ Mercer teoreminde belirtilen koşulları sağlayan çekirdek fonksiyonudur.

5. EEG ve EKG İŞARETLERİNDE ÖRÜNTÜ TANIMA ve UYGULAMALARI


Bölüm 4’de bu tez çalışmasının konusu olan biyolojik EEG ve EKG işaret örüntüleri için gerçekleştirilecek örüntü tanıma sistemlerinin, özellik tanımlama ve sınıflandırma sürecinde kullanılabilecek teknikler tanıtılmıştır. Bu bölümde ise EEG ve EKG işaretleri için bu teknikleri kullanarak oluşturulan örüntü tanıma sistemleri ve uygulamaları verilmiştir. Örüntü tanıma sisteminin EEG uygulaması ile kişinin uyanıklık seviyesinin üç durumu olan uyanık, uyuklama ve uyku durumları EEG işaretlerinden tespit edilmeye çalışılmıştır. Örüntü tanıma sisteminin EKG uygulamasında ise EKG işaretlerinden OUAS hastalığı tespit edilmeye çalışılmıştır.

5.1. EEG İşaretlerinden Uyanıklık Seviyesini Tespit Eden Örüntü Tanıma Sistemi ve Uygulamaları

Bu çalışmanın temel amaçlarından biri olan EEG işaretlerinden uyanıklık seviyesinin tespitini yapan örüntü tanıma sistemi, özellik çıkarma ve sınıflandırma olmak üzere iki temel aşamadan oluşmaktadır. Özellik çıkarma, durağan olmayan ve aynı zamanda veri boyutu yüksek olan EEG işaretlerinin gereksiz ve ilişkisiz bilgilerden arındırılarak kararlı ve olabildiğince daha küçük boyutlu bir bilgi ile temsil edildiği aşamadır. Bu aşamada, iki farklı özellik çıkarma yöntemi kullanılmıştır. Bu yöntemlerden birincisi, DD ve entropi hesaplama tekniğine dayalı olan yöntemdir. Bu yöntemde, DD ile EEG işaretleri alt bileşenlerine (Delta, Teta, Alfa, Beta vb.) ayrıştırılarak bunlar arasından uyanıklık seviyesinin tespitinde karakteristik özellikte olan bileşenler belirlenmiştir. Daha sonra, belirlenen bu bileşenlerin her birinin entropisi hesaplanarak her bileşen bir değer ile ifade edilmiştir. Böylelikle, veri boyutu yüksek olan EEG işareti gereksiz ve ilişkisiz bilgilerden arındırıldığı gibi daha düşük boyutlu bir bilgi ile temsil edilmesi amaçlanmıştır. Bu bilgi, EEG işaret bileşenlerinin zaman uzayındaki gösterimlerinin değişim bilgisidir. İkinci özellik çıkarma yöntemi ise DD, Welch GSY ve entropi hesaplama tekniğinin birlikte kullanıldığı yöntemdir. Bu yöntemde de öncelikle DD ile uyanıklık seviyesinin tespitinde karakteristik özellikte olan EEG işaret bileşenleri belirlenmiştir. Daha sonra belirlenen her EEG bileşeninin frekans uzayındaki güç dağılım bilgisi veya başka bir ifadeyle GSY bilgisini elde etmek için Welch yöntemi kullanılmıştır. Son olarak her bileşenin elde edilen GSY bilgisinin entropisi hesaplanarak her bileşen bir değer ile ifade

edilmiştir. Böylelikle birinci özellik çıkarma yönteminde olduğu gibi ikinci özellik çıkarma yöntemiyle de EEG işaret gereksiz ve ilişkisiz bilgilerden arındırıldığı gibi daha düşük boyutlu bir bilgi ile temsil edilmiş olur. İkinci özellik çıkarma yöntemiyle EEG işaretinden elde edilen bilgi, işaret bileşenlerinin frekans uzayındaki değişim bilgisidir. Oysa ilk özellik çıkarma yöntemiyle elde edilen bu bilgi EEG işaret bileşenlerinin zaman uzayındaki değişim bilgisidir.

Sunulan örüntü tanıma sisteminin özellik çıkarma aşamasından sonra gerçekleşen diğer bir aşama ise sınıflandırma aşamasıdır. Bu aşamada özellik çıkarma aşamasında kullanılan yöntemlerle elde edilen EEG işaret özelliklerini giriş olarak kullanan YSA, ANFIS ve EKK-DVM sınıflandırıcıları yardımıyla uyanıklık seviyesi; uyanık, uyuklama ve uyku olarak sınıflandırılmıştır. Kaba hatları ile tanıtımı yapılan örüntü tanıma sisteminin yapısı Şekil 5.1’de verilmiştir. Sistemin her bloğunda gerçekleştirilecek işlemlerin detayları ve uygulamaları ise çalışmanın ilerleyen alt bölümlerinde verilmiştir.




Şekil 5.1. EEG işaretlerinden uyanıklık seviyesine tespit eden örüntü tanıma sistemi.

5.1.1. EEG Verilerinin Toplanması

Çalışmada 14'ü kadın, 16'sı erkek olmak üzere 30 kişiye ait EEG verisi kullanılmıştır. Kişilerin yaş aralığı 18 ile 65 arasında olup yaş ortalaması 33.5 civarındadır. Çalışmada kullanılan 30 kişilik grup nörolojik kontrolden geçen sağlıklı kişilerden oluşmaktadır. EEG işaret kayıtlarının alınması, değerlendirilmesi ve derecelendirilmesi uyku çalışmaları için belirlenmiş olan uluslar arası etik kurallara göre yapılmıştır. EEG işaret kayıtlarının değerlendirilmesi ve derecelendirilmesi uyku çalışmaları konusunda uzman olan iki nörolog tarafından gerçekleştirilmiştir. Kişilerden alınan EEG kayıtlarının uyanık, uyuklama ve uyku durumuna ait kısımları (EEG işaretleri) belirlenirken, kayıtların her biri bu nörologlar tarafından ayrı ayrı incelenmiştir. Nörologlar yapmış oldukları incelemelerin sonuçlarını karşılaştırarak her EEG kaydının uyanık, uyuklama ve uyku durumuna karşılık gelen EEG işaretlerini belirlemişlerdir. Nörologların tasnifinde hemfikir olmadığı EEG işaretleri bu çalışmaya dahil edilmemiştir.

Çalışmada kullanılan bütün EEG verileri, Dicle Üniversitesi Tıp Fakültesi Uyku laboratuvarında, Grass Model-78 polisomnograf cihazı kullanılarak alınmıştır. Kayıt esnasında gümüş yüzey elektrotları kullanılmış ve elektrotların kafatasına yerleşim biçimi için standart C3-A2 derivasyonu kullanılmıştır. Polisomnografin kayıt esnasındaki işaret koşullama ayarları şu şekildedir: Band geçiren süzgeçler 0.3-70 Hz band aralığına ve duyarlılık seçimi ise 50 μV için 7.5 mm sapma duyarlılık derecesine getirilmiştir. Polisomnografin analog işaret çıkışı 150 Hz'lik örnekleme frekansı ile 12-bitlik çözünürlüğe sahip olan Avantech PCL 818HG analog-sayısal çevirici kartı üzerinden bilgisayara aktarılmıştır. Tüm kayıtlar gece boyunca yapılmıştır. Kayıtlar uyanıklık seviyesinin üç durumu olan uyanık, uyuklama ve uyku durumlarının belirlenmesi için iki uzman tarafından değerlendirilmiştir. Değerlendirme sonucunda belirlenen uyanık, uyuklama ve uyku durumları 5'er saniyelik bölütler ile temsil edilmiştir. Şekil 5.2'de uyanıklık seviyesinin bu üç durumunu ait örnek EEG işaretleri verilmiştir. İşaretlerin genlik değerleri μV düzeyinde olup, $\times 10^7$ ile normalize edilmişlerdir. Bu çalışmada kullanılmak üzere tüm kayıtlardan alınan toplam bölüt sayısı 435'tir. Bu bölütlerin 145 tanesi uyanık duruma, 145 tanesi uyuklama durumuna ve 145 tanesi de uyku durumuna aittir.




Şekil 5.2. Üç farklı duruma ait EEG işaretleri: (a) Uyanık, (b) uyuklama, (c) uyku.

5.1.2. EEG İşaret Örüntülerinden Özellik Çıkarma

İşaret örüntülerinden özellik çıkarma, işaret verisine uygun matematiksel dönüşüm ve hesaplama tekniklerinin uygulanmasıyla, işaretin karakteristik özelliklerinin elde edilmesi işlemidir. Bu işlem ile örüntü tanıma sisteminin karar mekanizması olan sınıflandırıcının doğru karar verebilme başarımının artırılması amaçlanır. Bu çalışmada; uyanık, uyuklama ve uyku durumuna ait EEG işaret örüntülerini birbirinden ayırt edecek örüntü tanıma sisteminin özellik çıkarma aşmasında iki farklı yöntem kullanılmıştır. Kullanılan özellik çıkarma yöntemlerinden ilki DD ve entropi hesaplama tekniğine dayalı olan yöntemdir. Bu yöntemin sunumu ve EEG işaretlerine uygulaması 5.1.2.1. alt başlığı altında verilmiştir. İkinci özellik çıkarma yöntemi ise DD, Welch GSY ve entropi hesaplama tekniğinin birlikte kullanıldığı yöntemdir. Bu yöntemin sunumu ve EEG işaretlerine uygulaması da 5.1.2.2. alt başlığında verilmiştir. Kullanılan her özellik çıkarma yöntemi ile EEG işareti gereksiz ve ilişkisiz bilgilerden arındırılarak normal veri boyutuna göre çok daha düşük boyutlu veri ile temsil edilmeye çalışılmıştır. Yöntemlerin dayalı olduğu işaret işleme tekniklerinin teorik matematiksel alt yapısı bölüm 4.2’de verilmiştir.

5.1.2.1. Dalgacık Dönüşümünden Entropi Hesaplanması

EEG işaret örüntülerinden özellik çıkarımı için kullanılan Dalgacık Dönüşümünden Entropi Hesaplama (DD-EH) ile özellik çıkarımı yönteminin blok diyagramı Şekil 5.3’de verilmiştir.



Şekil 5.3. EEG işareti için DD bileşenlerinin entropisi ile özellik çıkarımın blok diyagramı.

Blok diyagramın her aşamasında gerçekleştirilen işlemler ve bu işlemlerin EEG işaretine uygulanması aşağıda sunulmuştur:


1. DD ile işaretin alt bileşenlerine ayrıştırılması:

İşaretin ADD ile analizinde uygun dalgacık tipi seçimi ve ayrışım seviyelerinin sayısının tespiti oldukça önemlidir [108]. İşaretin ayrışım seviyelerinin sayısı, genelde işaretin baskın frekans bileşenlerine göre tespit edilir. Bu çalışmada, örnekleme frekansı 150 Hz olan EEG işaretlerini, baskın frekans bileşenleri olan Delta (1-4 Hz), Teta (4-8 Hz), Alfa (8-13 Hz) ve Beta (13-30 Hz) alt bantlarına ayrıştırabilmek için ayrışım seviyelerinin sayısı 4 olarak belirlenmiştir. Bu durumda, EEG işaretleri Tablo 5.1’de verildiği gibi D_1 - D_4 detayları ve son olarak A_4 yaklaşık alt bantlarına ayrıştırılmış olur. İşaretin ADD ile analizinde ayrışım seviyelerinin sayısının tespitinin yanı sıra diğer önemli bir etken ise uygun dalgacık tipinin seçimidir. Uygun dalgacık

tipi seçimi için genelde farklı dalgacık tipleri denenir. Bu denemeler sonucunda işaretlerdeki değişimleri en iyi ortaya çıkarabilen dalgacık tipi, uygun dalgacık tipi olarak seçilir. Bu çalışmada, EEG işaretlerindeki değişimlerin belirlenmesi için kullanılabilecek en uygun dalgacık tipinin Daubechies dalgacık ailesinin 12. dereceden dalgacık tipi (db12) olduğu görülmüştür. Böylelikle DD-EH özellik çıkarma yönteminin bu aşamasında, db12 kullanılarak EEG işaretlerinin D_1 - D_4 detay alt bantlarına ait katsayı işaretleri ve A_4 yaklaşık alt bandına ait katsayı işareti hesaplandı. Şekil 5.4’de, uyanık, uyuklama ve uykuya ait örnek EEG işaretlerinin DD ile elde edilen detay ve yaklaşık alt bantlarına ait katsayı işaretleri gösterilmiştir. Burada her alt banda ait katsayı işareti yeniden yapılandırılmıştır.

Tablo 5.1. DD ayrışımındaki frekans bantlarının aralıkları.

Alt bantlar	Frekans aralığı (Hz)
D_1	37.5-75
D_2	18.75-37.5
D_3	9.375-18.75
D_4	4.6875-9.375
A_4	0-4.6875



Şekil 5.4. (a) uyanık, (b) uyuklama ve (c) uyku EEG işaretlerinin 4. seviyeden DD’leri.

2. Uygun alt bileşenlerin seçilmesi:


Bu aşama, EEG işaretinin alt bileşenleri (D_1 - D_4 ve A_4) arasından uyanık, uyuklama ve uykuyu ayırt etmede önemli bilgiler içeren uygun alt bileşenlerin seçildiği aşamadır. Daha öncede ifade edildiği üzere EEG işaretlerinin baskın frekans bileşenleri Delta, Teta, Alfa ve Beta alt bantlarıdır. Bu alt bantların aktiviteleri, beyin aktivite düzeyine göre veya başka bir ifadeyle kişinin uyanık, uyuklama ve uyku durumlarına göre değişkenlik gösterir. EEG işaretlerine ADD uygulanarak elde edilen alt bantların kapsadığı frekans aralıkları (Tablo 5.1) ile EEG işaretlerinin baskın frekans bileşenleri olan Delta (1-4 Hz), Teta (4-8), Alfa (8-13) ve Beta (13-30) alt bantlarının kapsadığı frekans aralıkları karşılaştırıldığında, D_1 (37.5-75Hz) detay alt bandının baskın frekans bileşenleri dışında kaldığı açıkça görülebilmektedir. Ayrıca bu karşılaştırmadan D_2 , D_3 , D_4 detay ve A_4 yaklaşık alt bantlarının sırasıyla Beta, Alfa, Teta ve Delta baskın frekans bileşenleri ile büyük oranda örtüştüğü anlaşılmaktadır. Dolayısıyla yapılan bu karşılaştırma ile EEG'nin önemli bilgiler içeren alt bantlarının D_2 , D_3 , D_4 detay, A_4 yaklaşık alt bantları olduğu sonucuna varmak mümkündür. Ancak; EEG işaretlerinin Şekil 5.4'deki ADD analizleri karşılaştırıldığında uyku, uyuklama ve uykuyu ayırt etmede detay katsayı işaretlerinin (D_2 , D_3 , D_4) yaklaşık katsayı işaretine (A_4) göre daha ayırt edici bilgiler içerdiği açıkça görülmüştür. Yapılan karşılaştırma sonuçlarından yola çıkarak EEG işaretleri için ayırt edici bilgilerin büyük oranda D_2 , D_3 ve D_4 detay alt bantlarında yoğunlaştığı sonucuna varılmıştır. Bundan dolayı bu üç detay alt bandına ait katsayı işaretleri EEG işaretini temsil eden bileşenler olarak seçilmiştir. Burada her alt banda ait katsayı işaretinin veri sayısı 750'dir (Şekil 5.4).

3. Seçilen her alt bileşen için entropi hesaplanması:

Bir önceki aşamada D_2 , D_3 ve D_4 detay alt bantlarına ait katsayıların EEG işaretlerini temsil eden bileşenler olarak seçilmiş olması, her EEG işaretinin 750x3 sayıda veri ile temsil edilmiş olduğunu gösterir. Bu sayıdaki veri, bir sınıflandırıcı için oldukça fazladır. Fazla sayıdaki veri, sınıflandırma performansını ve hızını olumsuz yönde etkileyecektir. Bundan dolayı özellik çıkarımının bu son aşamasında veri sayısını azaltma yoluna gidilmiştir. Veri sayısını azaltmak için, Logaritmik Enerji entropi hesaplama tekniği kullanılarak her detay alt bandına ait katsayı işaretinin entropi değeri Denklem 5.1'de gösterildiği gibi hesaplanmıştır.

$$E_i = \sum_{n=1}^{750} \log_2(D_{i+1}^2[n]), \quad i = 1, 2, 3 \quad (5.1)$$


Burada, D_{i+1} $i+1$. detay alt bandına ait katsayı işaretidir. E_i ise bu katsayı işaretinin Logaritmik Enerji entropi değeridir. Böylece çok sayıda veriden oluşan her detay alt bandına ait katsayı işareti, bir entropi değeri ile karakterize edilmiş olunacağından her EEG işareti 3 veriden oluşan bir özellik vektörü ($[E_1, E_2, E_3]$) ile temsil edilmiş olur. Farklı durumlara ait örnek EEG işareti için elde edilen özelliklerin grafiksel gösterimleri Şekil 5.5’de verilmiştir.



Şekil 5.5. (a) uyanık, (b) uyuklama ve (c) uyku EEG işaretlerinin DD-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.

5.1.2.2. Dalgacık Dönüşümü ve Welch GSY ile Entropi Hesaplanması

EEG işaret örüntülerinden özellik çıkarımı için kullanılan DD ve Welch GSY ile Entropi Hesaplanması (DD-WGSY-EH) özellik çıkarımı yönteminin blok diyagramı gösterimi Şekil 5.6’da verilmiştir.



Şekil 5.6. EEG işareti için DD ve Welch GSY kestirimi entropileri ile özellik çıkarımın blok diyagramı.

Blok diyagramın her aşamasında gerçekleştirilen işlemler ve bu işlemlerin EEG işaretine uygulaması aşağıda verilmiştir:

1. DD ile işaretin alt bileşenlerine ayrıştırılması:


DD-WGSY-EH özellik çıkarımı yönteminin bu ilk aşamasında gerçekleştirilen işlemler, bölüm 5.1.2.1’de verilmiş olan DD-EH özellik çıkarımı yönteminin ilk aşamasında gerçekleştirilen işlemlerle aynıdır. Yani, EEG işaretleri DD ile 4’ü detay katsayı işareti (D_1 - D_4) ve 1’i yaklaşık katsayı işareti (A_4) olmak üzere 5 alt bileşene (işarete) ayrıştırılmıştır (Şekil 5.4).

2. Uygun alt bileşenlerin seçilmesi:

DD ayrıştırması ile elde edilen D_1 - D_4 detay ve A_4 yaklaşık katsayı işaretleri arasından D_2 , D_3 ve D_4 detay katsayı işaretleri EEG işaretini temsil eden bileşenler olarak seçilmiştir. EEG işaretinin temsilinde D_2 , D_3 ve D_4 katsayı işaretlerinin seçilme sebepleri bölüm 5.1.2.1’de belirtilmiştir.

3. Seçilen her alt bileşenin Welch yöntemi ile GSY kestirimi:

Bir önceki aşamada EEG işaretini temsil etmek amacıyla seçilmiş olan D_2 , D_3 ve D_4 detay katsayı işaretleri, EEG işaretinin önemli bilgiler içeren zaman bölgesi bileşenleridir. Bu aşamada ise bu katsayı işaretlerinin frekans bölgesi bilgilerine ulaşmak için Welch yöntemi kullanılarak her katsayı işaretinin GSY'si hesaplanmıştır. Bölüm 4.2.3'de bahsedildiği gibi, bir işaretin Welch yöntemi ile GSY'si hesaplanırken; öncelikle işaret üst üste binmiş (overlapped) parçalara ayrılır, sonra her bir parça uygun bir pencere fonksiyonu ile pencerelenir, daha sonra pencerelenmiş her bir parçanın periyodogramı hesaplanır ve son olarak hesaplanmış periyodogramların ortalaması alınır [111]. Bu çalışmada D_2 , D_3 ve D_4 detay katsayı işaretlerine Welch yöntemi uygulanırken, pencere fonksiyonu olarak 100 noktalı Hanning pencere fonksiyonu kullanılmış ve parçaların üst üste binme oranı %50 (50 örnek) olarak seçilmiştir. Dolayısıyla her bir katsayı işareti, %50 oranında örtüşen ve 100 örnek uzunluğunda olan 13 ayrı parçaya ayrıştırılmıştır. Ayrıca, periyodogram hesaplama işleminin HFD tabanlı olması dolayısıyla parçaların periyodogramları hesaplanırken 128 noktalı HFD kullanılmıştır. Böylelikle her katsayı işaretinin welch yöntemiyle elde edilen GSY'si 65 örnek uzunluğunda olmuştur. Şekil 5.7'de, farklı durumlara ait örnek EEG işaretinin D_2 , D_3 , D_4 detay katsayı işaretlerinin Welch yöntemi ile elde edilen GSY'leri verilmiştir. Burada, D_2 , D_3 ve D_4 detay katsayı işaretlerinin GSY'leri sırasıyla P_{D2} , P_{D3} ve P_{D4} olarak gösterilmiştir.



Şekil 5.7. (a) uyanık, (b) uykulama ve (c) uyku EEG işaretlerine ilişkin D_2 , D_3 , D_4 katsayılarının Welch yöntemi ile elde edilen GSY'leri.


4. GSY kestirimi yapılan her alt bileşen için entropi hesaplanması:

Bir önceki aşamada, EEG işaretinin DD detay katsayı işaretleri olan D_2 , D_3 ve D_4 'ün Welch yöntemi ile elde edilen GSY gösterimlerinin her biri 65 örnek uzunluğundadır. Dolayısıyla her EEG işaretini (bölütü) karakterize eden verinin boyutu da 3×65 olacaktır. Bu boyuttaki veri sınıflandırma aşamasının hesap yükünü büyük oranda artıracığından özellik çıkarımının bu son aşamasında veri boyutunu azaltma yoluna gidilmiştir. Veri boyutunu azaltmak için, Logaritmik Enerji entropi hesaplama tekniği kullanılarak her detay katsayı işaretinin GSY gösteriminin entropi değeri Denklem 5.2'de gösterildiği gibi hesaplanmıştır.

$$E_i = \sum_{n=1}^{65} \log_2(P_{D_{i+1}}^2[n]), \quad i=1,2,3 \quad (5.2)$$

Burada, $P_{D_{i+1}}$ $i+1$. detay katsayı işaretinin GSY gösterimidir. E_i ise bu GSY gösteriminin Logaritmik Enerji entropi değeridir. Böylece çok sayıda veriden oluşan her

detay katsayı işaretinin GSY gösterimi, bir entropi değeri ile karakterize edilmiş olunacağından her EEG işareti de 3 veriden oluşan bir özellik vektörü (E_1, E_2, E_3) ile temsil edilmiş olur. Farklı durumlara ait Örnek EEG işareti için elde edilen özelliklerin grafiksel gösterimleri Şekil 5.8’de verilmiştir.



Şekil 5.8. (a) uyanık, (b) uyuklama ve (c) uyku EEG işaretlerinin DD-WGSY-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi

5.1.3 EEG İşaret Örüntülerini Sınıflandırma

Burada 5.1.2 bölümünde elde edilen EEG işaret özellikleri kullanılarak uyanıklık seviyesi; uyanık, uyuklama ve uyku olarak sınıflandırılmıştır. DD-EH ve DD-WGSY-EH esaslı özellik çıkarım yaklaşımları ile elde edilen EEG işareti ait özellikler üç farklı sınıflandırıcı ile sınıflandırılmaktadır. Bu sınıflandırıcılar YSA, ANFIS ve EKK-DVM sınıflandırıcılarıdır. Böylece, DD-EH ve DD-WGSY-EH özellik çıkarım yöntemleri ile YSA, ANFIS ve EKK-DVM sınıflandırıcılardan oluşturulan farklı kombinasyonların EEG işaretlerinden uyanıklık seviyesini belirleme performansları test edilmeye çalışılmıştır. EEG işaretlerinden uyanıklık seviyesini belirlemek için oluşturulan özellik çıkarım ve sınıflandırıcı kombinasyonları Tablo 5.2’de belirtildiği gibidir.

Tablo 5.2. Özellik çıkarım ve sınıflandırıcı kombinasyonları.

Kombinasyon 1	DD-EH / YSA
Kombinasyon 2	DD-WGSY-EH / YSA
Kombinasyon 3	DD-EH / ANFIS
Kombinasyon 4	DD-WGSY-EH / ANFIS
Kombinasyon 5	DD-EH / EKK-DVM
Kombinasyon 6	DD-WGSY-EH / EKK-DVM

Tüm sınıflandırma kombinasyonlarında her biri 5 saniyelik süreden oluşan toplam 435 adet EEG işaret bölütü kullanılmıştır. EEG işaret bölütlerinin alındığı denek adedi 30'dur. Bu EEG işaret bölütlerinin 145'i deneklerin uyanık durumuna, 145'i ise deneklerin uyuklama durumuna ve geriye kalan 145 adedi de deneklerin uyku durumuna aittir. 18 deneğe ait 255 adet EEG işaret bölütünün özellik vektörleri (3x255) eğitim veri kümesi olarak kullanılmıştır. 12 deneğe ait 180 adet EEG işaret bölütünün özellik vektörleri (3x180) ise test veri kümesi olarak kullanılmıştır. Tablo 5.3'de eğitim veri kümesi ve test veri kümesine ilişkin detaylı bilgi sunulmaktadır.

Tablo 5.3. Eğitim veri kümesi ve test veri kümesi detayı.

	Bölüt Adedi			
	Uyanık durumu	Uyuklama durumu	Uyku durumu	Toplam
Eğitim veri kümesi	85	85	85	255
Test veri kümesi	60	60	60	180

Gerçekleştirilen YSA tabanlı sınıflandırmalar bölüm 5.1.3.1'de, ANFIS tabanlı sınıflandırmalar bölüm 5.1.3.2'de ve EKK-DVM tabanlı sınıflandırmalar bölüm 5.1.3.3'de sunulmaktadır. Çalışmada kullanılan YSA, ANFIS ve EKK-DVM sınıflandırıcılarına ilişkin teorik matematiksel alt yapı ise daha önce bölüm 4.3'de verilmişti.


5.1.3.1. Yapay Sinir Ağları Tabanlı Sınıflandırma

Burada, DD-EH ve DD-WGSY-EH esaslı özellik çıkarım yaklaşımları ile elde edilen EEG işaretlerine ait özellikler YSA ile sınıflandırılmıştır. Çalışmada YSA modeli olarak yapay sinir ağları uygulamalarında en sık tercih edilen ÇKA modeli kullanılmıştır [99, 124]. Kullanılan YSA modelinin eğitim parametreleri ve yapısı Tablo 5.4'de verilmiştir.

Tablo 5.4. Kullanılan YSA modelinin yapısı ve eğitim parametreleri.

YSA yapısı	
YSA modeli	Çok katmanlı algılayıcı (ÇKA)
Katman sayısı	3
Katmanlardaki yapay hücre sayısı	Giriş : 3 Ara : 10 Çıkış : 3
Başlangıç ağırlıkları ve eşik değerleri	Rastgele
Aktivasyon fonksiyonları	Logaritmik sigmoid
YSA eğitim parametreleri	
Öğrenme kuralı	Hata geriye yayma (Resilient)
Öğrenme oranı	0.01
Toplam karesel hata	Özellik çıkarım yöntemine göre değişken

Burada modelin ara katmanındaki yapay hücre sayısı, ara ve çıkış katmanındaki hücrelerin kullandığı aktivasyon fonksiyonlarının türleri ve öğrenme oranı değeri, birkaç deneme ile en iyi başarımlar için seçilmiştir. Kullanılan YSA sınıflandırıcı modelin, EEG işaretlerinin DD-EH özellik çıkarım yöntemine göre elde edilen özellikleri (eğitim veri kümesi) ile eğitiminin başarı performansı Şekil 5.9a’de verilmiştir. Bu modelin, EEG işaretlerinin DD-WGSY-EH özellik çıkarım yöntemi ile elde edilen özellikleri (eğitim veri kümesi) ile eğitiminin başarı performansı ise Şekil 5.9b’de görülmektedir. Kullanılan özellik çıkarım yöntemine göre YSA sınıflandırıcı modelin test veri kümesi üzerindeki uygulama başarımlar sonuçları ise karşılaştırmalı olarak Tablo 5.5’de verilmiştir.



Şekil 5.9. (a) DD-EH ve (b) WGSY-EH özellik çıkarım yöntemlerine göre YSA tabanlı sınıflandırıcının eğitim performansı.

Tablo 5.5. Kullanılan özellik çıkarım yöntemine göre YSA sınıflandırıcı modelin EEG işaret örüntülerini tanıma başarımı.


Özellik Çıkarım Yöntemi	DD-EH			DD-WGSY-EH		
	Uyanık	Uyuklama	Uyku	Uyanık	Uyuklama	Uyku
EEG işaret sınıfı						
Sınıfa ait işaret Adedi	60	60	60	60	60	60
Yanlış Sınıflama Adedi	2	11	3	2	4	1
Doğru Sınıflama Adedi	58	49	57	58	56	59
Doğruluk Yüzdesi	96.7	81.7	95	96.7	95	100
Toplamda Doğruluk Yüzdesi	164/180 91.1			173/180 96.1		

5.1.3.2. ANFIS Tabanlı Sınıflandırma

Bölüm 4.3.2’de belirtildiği gibi ANFIS, Takagi-Sugeno bulanık mantık çıkarım sisteminin insan gibi karar verme ve uzman bilgisi sağlama yeteneği ile YSA ‘nın

örneklerden öğrenebilme yeteneğini yapısında barındıran bir adaptif sinirsel bulanık modeldir [123].

Burada, DD-EH ve DD-WGSY-EH esaslı özellik çıkarım yaklaşımları ile elde edilen EEG işaret bölütlerine ait özellik vektörleri sınıflandırılırken 4 ANFIS modelinin birleşiminden oluşan bir sınıflandırıcı yapısı kullanılmıştır [152]. ANFIS tabanlı bu sınıflandırıcının blok diyagramı gösterimi Şekil 5.10’da verildiği gibidir.




Şekil 5.10. ANFIS tabanlı sınıflandırıcı.

Blok diyagramı verilen ANFIS tabanlı bu sınıflandırıcı ile EEG işaret örüntülerine ait özellik vektörleri sınıflandırılırken ANFIS1, ANFIS2 ve ANFIS3 modelleri bir sınıfa karşı diğerleri prensibine göre eğitilir. Bu prensibe uygun olarak ANFIS1 uyanık durum ve diğerleri sınıflandırmasını yapacak şekilde eğitilir, ANFIS2 uyuklama durumu ve diğerleri sınıflandırmasını yapacak şekilde eğitilir ve ANFIS3 ise uyku durumu ve diğerleri sınıflandırmasını yapacak şekilde eğitilir. Sınıflandırma doğruluğunu iyileştirmek için bu 3 ANFIS sınıflandırıcısının çıkışlarını giriş olarak kullanan dördüncü bir ANFIS (ANFIS4) eğitilmiştir. Burada her ANFIS sınıflandırıcısının eğitimi için geri yayılım algoritması ile en küçük kareler yönteminin birleşiminden oluşan öğrenme kuralı kullanılmıştır. Her ANFIS 550 iterasyon için eğitilmiştir. ANFIS sınıflandırıcıların bulanık kural yapısının oluşturulmasında bölüm 4.2.3’de, (4.45) bağıntısı ile tanımlanan Gauss üyelik fonksiyonu kullanılmıştır. Her ANFIS sınıflandırıcısının her bir girişi için 2 gauss üyelik fonksiyonu atanmıştır. Dolayısıyla her ANFIS ‘in kural sayısı 8 ve öğrenme ile ayarlanabilir parametre

sayısı ise 12'si öncül parametre (premise parameters) 36'sı sonuç parametresi (consequent parameters) olmak üzere toplam 44'dür.

Kullanılan ANFIS tabanlı sınıflandırıcının, EEG işaretlerinin DD-EH özellik çıkarım yöntemine göre elde edilen özellikleri (eğitim veri kümesi) ile eğitiminin başarı performansı Şekil 5.11a'da verilmiştir. Bu sınıflandırıcının, EEG işaretlerinin DD-WGSY-EH özellik çıkarım yöntemi ile elde edilen özellikleri (eğitim veri kümesi) ile eğitiminin başarı performansı ise Şekil 5.11b'de görülmektedir. Kullanılan özellik çıkarım yöntemine göre ANFIS tabanlı sınıflandırıcının test veri seti üzerindeki uygulama başarımları ise karşılaştırmalı olarak Tablo 5.6'da verilmiştir.



Şekil 5.11. (a) DD-EH ve (b) WGSY-EH özellik çıkarım yöntemlerine göre ANFIS tabanlı sınıflandırıcının eğitim performansı.

Tablo 5.6. Kullanılan özellik çıkarım yöntemine göre ANFIS tabanlı sınıflandırıcının EEG işaret örüntülerini tanıma başarımı.

Özellik Çıkarım Yöntemi	DD-EH			DD-WGSY-EH		
EEG işaret sınıfı	Uyanık	Uyuklama	Uyku	Uyanık	Uyuklama	Uyku
Sınıfa ait işaret Adedi	60	60	60	60	60	60
Yanlış Sınıflama Adedi	3	8	4	0	2	1
Doğru Sınıflama Adedi	57	52	56	60	58	59
Doğruluk Yüzdesi (%)	95	96.7	93.3	100	96.7	98.3
Toplamda Doğruluk Yüzdesi (%)	165/180 91.7			177/180 98.3		

5.1.3.3. En Küçük Karalar Destek Vektör Makine Tabanlı Sınıflandırma

Burada, DD-EH ve DD-WGSY-EH esaslı özellik çıkarım yaklaşımları ile elde edilen EEG işaretlerine ait özellikler EKK-DVM ile sınıflandırılmıştır. EKK-DVM sınıflandırıcı, standart DVM sınıflandırıcısının yeniden düzenlenmiş bir türüdür [151]. EKK-DVM sınıflandırıcısının eğitiminde çekirdek fonksiyonu tipi olarak daha önce Tablo 4.4’de verilmiş olan radyal tabanlı çekirdek fonksiyonu kullanılmıştır. Kullanılan çekirdek fonksiyonun genişlik parametresi olan σ ’nin değeri 0.05 ve sınıflandırıcının düzenleme parametresi olan C ’nin değeri ise 1 olarak belirlenmiştir. σ ve C parametrelerinin aldığı değerler göre EKK-DVM sınıflandırıcısının sınıflandırma performansı değişebilmektedir. Burada bu iki parametrenin aldığı değerler birkaç deneme ile en iyi performans için belirlenmiş değerlerdir.

Kullanılan EKK-DVM sınıflandırıcının, EEG işaretlerinin DD-EH özellik çıkarım yöntemine göre elde edilen özellikleri (eğitim veri seti) ile eğitiminin başarımlı performansı %90.6 olarak gerçekleşmiştir. EEG işaretlerinin DD-WGSY-EH özellik çıkarım yöntemi ile elde edilen özellikleri (eğitim veri seti) ile eğitiminin başarımlı performansı ise %95 olarak gerçekleşmiştir. Kullanılan özellik çıkarım yöntemine göre EKK-DVM sınıflandırıcının test veri seti üzerindeki uygulama başarımlı sonuçları ise karşılaştırmalı olarak Tablo 5.7’de gösterildiği gibidir.

Tablo 5.7. Kullanılan özellik çıkarım yöntemine göre EKK-DVM sınıflandırıcı modelin EEG işaret örüntülerini tanıma başarımı.

Özellik Çıkarım Yöntemi	DD-EH			DD-WGSY-EH		
EEG işaret sınıfı	Uyanık	Uyuklama	Uyku	Uyanık	Uyuklama	Uyku
Sınıfa Ait İşaret Adedi	60	60	60	60	60	60
Yanlış Sınıflama Adedi	3	11	7	2	6	3
Doğru Sınıflama Adedi	57	49	53	58	54	57
Doğruluk Yüzdesi (%)	95	81.7	88.3	96.7	90	95
Toplamda Doğruluk Yüzdesi (%)	159/180 88.3			169/180 93.9		


5.2. EKG İşaretlerinden OUAS Hastalığını Tespit Eden Örüntü Tanıma Sistemi ve Uygulamaları

Bölüm 5.1’de EEG işaretlerinden uyanıklık seviyesinin tespitini yapan örüntü tanıma sistemi sunulmuştu. Tez çalışmasının bu kısmında ise EKG işaret kayıtlarından OUAS hastası kişileri normal kişilerden ayırt edebilen bir otomatik örüntü tanıma sistemi sunulmuştur. Sunulan örüntü tanıma sistemi ön işleme, özellik çıkarma ve sınıflandırma olmak üzere üç temel aşamadan oluşmaktadır. Sistemin ön işleme aşamasında DD’ye dayalı bir algoritma kullanarak öncelikle EKG kayıtları içerisindeki QRS komplekslerinin maksimum genlik konumları (R tepeleri) tespit edilmiştir. Daha sonra tespit edilen bu genlik konumlarından yararlanılarak her EKG işaret kaydının ardışık R-R aralıkları ve QRS komplekslerinin altındaki alanlar hesaplanmıştır. Hesaplanan R-R aralıkları kişinin KHD bilgisini/işaretini verirken [33-36], hesaplanan QRS kompleksleri altındaki alanlar ise kişinin ETS bilgisini/işaretini gösterir [37, 38]. Dolayısıyla örüntü tanıma sisteminin ön işleme aşaması ile her EKG işaret kaydından biri KHD işareti diğeri de ETS işareti olmak üzere iki farklı işaret elde edilmiştir.

Örüntü tanıma sisteminin ön işleme aşamasından sonra özellik çıkarımı aşamasına geçilir. Özellik çıkarımı aşaması, EKG’den elde edilen KHD ve ETS işaretlerinin anlamlı ve daha düşük boyutlu verilerle karakterize edildiği aşamadır. Bu aşamada iki ayrı özellik çıkarma yöntemi kullanılmıştır. Kullanılan özellik çıkarma yöntemlerinin biri DD ve

entropi hesaplama tekniğine dayalıyken diğeri ise DD, Welch GSY ve entropi hesaplama tekniğine dayalıdır. Bu iki özellik çıkarma yönteminin EEG işaretlerine uygulanması daha önce bölüm 5.1.2’de verilmişti. Burada ise bu iki özellik çıkarma yöntemi KHD ve ETS işaretlerine uygulanmıştır. Böylelikle hem KHD işareti hem de ETS işareti iki farklı biçimde karakterize edilmiş olur.

Örüntü tanıma sisteminin özellik çıkarma aşamasından sonraki aşaması ise sınıflandırma aşamasıdır. Bu aşamada, özellik çıkarma aşamasında kullanılan yöntemlerle karakterize edilen KHD ve ETS işaretlerini giriş olarak kullanan YSA ve EKK-DVM sınıflandırıcıları yardımıyla EKG kayıtları, OUAS’lı (hastalıklı) ve normal (sağlıklı) olarak sınıflandırılmıştır. Kaba hatları ile tanıtımı yapılan örüntü tanıma sisteminin yapısı Şekil 5.12’de verilmiştir. Sistemin her bloğunda gerçekleştirilecek işlemlerin detayları ve uygulamaları ise çalışmanın ilerleyen alt bölümlerinde verilmiştir.



Şekil 5.12. EKG işaretlerinden OUAS hastalığını tespit eden örüntü tanıma sistemi.

5.2.1. Kullanılan EKG Verileri

Bu çalışmada OUAS hastalığının teşhisi için kullanılan EKG işaretleri “*physionet apnoea-ECG database*” adlı veri bankasından alınmıştır [153]. Veri bankası toplam 70 EKG kaydından oluşmaktadır. Kayıtlar gece uykusu esnasında yapılmış olup her kayıt yaklaşık 8 saattir. Uyku kayıtlarının tümü 32 denekten alınmıştır. Bu deneklerin 25’i erkek, 7’si ise kadındır. Deneklerin yaş aralığı 27 ile 63 arasında olup yaş ortalaması ise 43.8 civarındadır. Kayıtların denekler göre dağılımı şu şekildedir: Dört denneğin her birinden birer kayıt, 22 denneğin her birinden ikişer kayıt, iki denneğin her birinden üçer kayıt ve dört denneğin her birinden dörder kayıt alınmıştır. Kayıtlar PSG tekniği dahilinde alınmış ve değerlendirilmiştir. Kayıt esnasında elektrotların vücut yüzeyine yerleşim biçimi için standart V_2 derivasyonu kullanılmıştır. EKG işaretleri 16 bitlik çözünürlük ile 100 Hz ‘de örneklenerek sayısallaştırılmıştır.

EKG kayıtlarının OUAS hastası kişiye ait olup olmadığının değerlendirilmesi PSG tekniği olarak da adlandırılan uyku çalışma tekniğine göre yapılmıştır. Uyku çalışma tekniği ile EKG kayıtlarının her dakikası değerlendirilerek uyku apnesi (uyku esnasındaki solunum tıkanması) barındırıp barındırmadığına bakılmıştır. Yapılan bu değerlendirme sonucunda kayıtlar aşağıda verildiği gibi 3 gruba ayrıştırılmıştır:

A Grubu (OUAS’lı grup): Bu grupta yer alan EKG kayıtları OUAS hastası olarak tanımlanmıştır. Kayıtların içerdiği uyku apneli dakika sayısı 100 ve üzeri, AHI ise 10 ve üzeri olarak değişmektedir. Bu gruptaki yer alan kayıt sayısı 40’dır.

B Grubu (hafif OUAS’lı grup): Bu gruptaki EKG kayıtlar hafif OUAS hastası olarak tanımlanmıştır. Grupta yer alan kayıtların uyku apneli dakika sayısı 5 ile 99 arasında, AHI ise 5 ve üzeri olarak değişmektedir. Grupta yer alan kayıt sayısı 10’dur.

C Grubu (Sağlıklı veya Normal grup): Bu grupta yer alan EKG kayıtları sağlıklı kayıtlar olarak tanımlanmıştır. Kayıtların uyku apneli dakika sayısı 5’in altındadır. Bu grupta yer alan kayıt sayısı 20’dir.

Bu çalışmada B grubunda yer alan kayıtlar çalışmaya dahil edilmemiştir. Yapılan çalışma, 40 OUAS hastası kayıt içeren A grubu ile 20 Normal (OUAS hastası olmayan) kayıt

içeren C grubunu kapsamaktadır. Amaç bu iki grubu birbirinden ayıracak otomatik bir örüntü tanıma sistemi sunmaktır.

5.2.2. Ön-işlem Süreci: EKG İşaretlerinden KHD ve ETS İşaretlerinin Elde Edilmesi

Bölüm 3.1’de ayrıntıları ile anlatıldığı gibi EKG işaretleri P, QRS kompleksi ve T olarak adlandırılan üç temel dalgadan oluşmaktadır (Şekil 3.1). EKG işaretini oluşturan bu dalgaların oluşum sırası önce P, ardından QRS kompleksi ve son olarak T olacak biçimdedir. Dolayısıyla bir EKG işaret kaydı bu oluşum biçiminin tekrarından oluşur. EKG işaretinin en karakteristik dalgası QRS kompleksidir ve ardışık iki QRS kompleksinin R tepeleri arasındaki mesafe (süre) R-R aralığı olarak adlandırılır. Bu aralık iki kalp atımı arasında geçen süreyi verir. Bununla birlikte süreklilik gösteren uzun süreli EKG işaret kayıtları için bulunan R-R aralıkları değişkenliği ise KHD bilgisi veya işareti olarak ifade edilir [75]. Daha önceki çalışmalar, EKG işaret kayıtlarından elde edilen KHD işaretlerinin analizinin OUAS tanısında başarıyla kullanılabileceğini göstermiştir [34-36].

KHD işaret analizinin yanı sıra EKG işaretlerinin solunum kaynaklı genlik değişimleri bilgisinin de OUAS tanısında kullanılabileceği bildirilmektedir [41, 86]. Çünkü göğüs yüzeyinden kaydedilen EKG işareti, soluk alıp verme esnasında göğse bağlı elektrotun kalbe göre hareketinden ve akciğerlere hava dolup boşalırken göğüs boşluğu empedansındaki değişimlerden etkilenmektedir [37, 38]. Solunum kaynaklı bu etki, EKG’de solunum döngüsü ile aynı frekansta genlik modülasyonuna sebebiyet verir. Bu çalışmada, EKG’nin genliğini modüle eden bu etkiyi EKG işaret kaydından elde edebilmek için kayıt içersinde yer alan her QRS kompleksi R tepe noktasının 50ms (5 örnek) sağ ve 50ms (5 örnek) solu ile sınırlı alan hesaplandı. Hesaplanan her alan bu etkinin bir örneğine (noktasına) karşılık gelir. Bu şekildeki hesaplama ile EKG işaretinden elde edilen bu etki, solunum kaynaklı ve solunumun bir benzetimi olması sebebiyle “EKG’den türetilen solunum (ETS) işareti” olarak adlandırılmıştır [37, 38].

KHD işaretinin ardışık QRS komplekslerinin tepe aralıklarından (R-R aralıkları) ve ETS işaretinin ise ardışık QRS komplekslerinin belirtilen sınırlar içersindeki alanlarından hesaplanarak elde edilebilmesi için öncelikle QRS komplekslerinin EKG içersindeki R tepe konumlarının tespit edilmesi gerekir. Ancak QRS dalgasının 10- 25 Hz frekans bandı aralığında yapısal değişkenlik göstermesi, 0.5-10 Hz frekans bandı aralığında bulunan P ve T dalgalarının genlik olarak QRS ile benzerlik göstermesi ve EKG’nin çeşitli gürültüler

barındırması gibi sebeplerden dolayı QRS kompleksinin EKG içersindeki konum tespiti kolay olmamaktadır. QRS kompleksinin konum tespitinin doğru yapılabilmesi için bu problemlerin üstesinden gelecek bir algoritma geliştirmek şarttır [87]. Bu çalışmada EKG işaretlerinin DD analizine dayalı basit bir algoritma kullanılarak EKG işaret kayıtları içersindeki QRS komplekslerinin R tepe konumları tespit edilmiş ve tespit edilen bu tepe konumları kullanılarak KHD ve ETS işaretleri elde edilmiştir.


5.2.2.1 EKG işaretlerinin Dalgacık Dönüşümü ile Analizi

Bu çalışmada, örnekleme frekansı 100 Hz olan EKG işaretlerinin DD ile analizi için EKG işaretleri içersindeki QRS dalgasına yapısal benzerliğinden dolayı Daubechies 6 (db6) dalgacığı tipi kullanılmıştır. EKG işaretlerinin ayrışım seviyelerinin sayısı ise 7 olarak belirlenmiştir. Bu durumda, EKG işareti D1-D7 detay ve A7 yaklaşık alt bantlarına ayrıştırılmıştır (Tablo 5.8).

Tablo 5.8 EKG işaretinin DD ayrışımındaki frekans bantlarının aralıkları.

Alt bantlar	İdeal Frekans aralığı (Hz)
D1	25-50
D2	12.5-25
D3	6.25-12.5
D4	3.125-6.25
D5	1.5625-3.125
D6	0.78125-1.5625
D7	0.390625-0.78125
A7	0-0.390625


Bu ayrıştırma biçimi, her biri ortalama 8 saatten oluşan 60 EKG işaret kaydına dakika dakika uygulanmıştır. Şekil 5.13’de herhangi bir EKG işaret kaydının bir dakikalık kısmının 7. seviyeden db6 DD ayrıştırması görülmektedir.



Şekil 5.13. Bir dakikalık orijinal EKG işareti ve bu işaretin 7. seviyeden DD ayrıştırması.

Şekil 5.13'deki EKG işareti ve bu işaretin DD ayrışımı ile elde edilen alt bantları karşılaştırıldığında, EKG'nin QRS dalgalarına ait enerjinin büyük oranda D2 detay alt bandında yoğunlaşmış olduğu, D2 detay alt bandında QRS dalgalarının R tepelerinin oldukça belirgin olduğu ve ayrıca D2 detay alt bandının P ve T dalgalarından büyük oranda izole olduğu açıkça görülmektedir. Bu özelliklerinden dolayı D2 detay alt bandı işareti QRS dalgalarının R tepe konumlarının tespitinde referans işaret olarak seçilmiştir. D2 detay alt bandının yanı sıra dikkat çeken diğer alt bant ise A7 yaklaşık bandıdır. A7 yaklaşık alt bandı orijinal EKG işareti ile karşılaştırıldığında bu alt bandın orijinal EKG işaretinin taban hattı sapmasına neden olan bileşene karşılık geldiği görülecektir. Literatürde “baseline wander” olarak ifade edilen ve frekans aralığı 0-0.5 Hz aralığında değişebilen EKG işaretlerinin taban hattı sapması, deneğin uyku esnasındaki hareketinden ve solunumundan kaynaklanan bir gürültü işaretidir [154]. Bu gürültü işareti, EKG

içersindeki QRS dalgalarının konum tespitini zorlaştırdığı gibi aynı zamanda bu konumların gerçek taban hattına ($y=0$) göre genliklerinin yanlış hesaplanmasına neden olur. İstenmeyen bu olumsuzlukları giderebilmek için bu olumsuzluklara neden olan taban hattı sapma gürültüsünün EKG işaretinden arındırılması gerekir. Literatürde bu işlem için çeşitli filtreleme tekniklerine başvurulmuştur [41, 154]. Bu çalışmada, EKG işaretinin taban hattı sapma gürültüsünden arındırılması için bu gürültüye karşılık gelen A7 yaklaşık bandı (0-0.39 Hz) işaretinin orijinal EKG işaretinden çıkarılması işlemine başvurulmuştur. Bu işlemin gerçekleştirilmesi ile Şekil 5.14b’da görüldüğü gibi Taban Hattı Sapmasından Arındırılmış EKG (THSA-EKG) işareti elde edilmiş olur.



Şekil 5.14. (a) Orijinal EKG işareti, (b) THSA-EKG işareti.

Bu çalışmada, EKG İşaret kayıtlarının DD analizi sonucu belirlenen D2 detay alt bant işareti ve THSA-EKG işareti birlikte kullanılarak QRS dalgalarının R tepe konumlarının tespit edilmiş ve tespit edilen bu konumlardan yararlanarak KHD ve ETS işaretlerinin hesaplanması yapılmıştır.

5.2.2.2. QRS Dalgaları R Tepe Konumlarının Tespit Edilerek KHD ve ETS İşaretlerinin Hesaplanması

Bölüm 5.2.2.1’de EKG işaretlerinin DD analizi verilmişti. Burada ise bu analize dayalı bir algoritma kullanılarak QRS dalgaları R tepe konumlarının tespit edilmesi ve tespit edilen bu tepe konumları referans alınarak KHD ve ETS işaretlerinin hesaplanması işlemleri gerçekleştirilmiştir. Ayrıca hesaplanan KHD ve ETS işaretlerinin normalizasyonu ve interpolasyonu gibi işlemleri de burada yapılmıştır.

QRS dalgaları R tepe konumlarını tespit eden ve tespit edilen bu tepe konumlarına kullanarak KHD ve ETS işaretlerini hesaplayan algoritma aşağıda adım adım verilmiştir [97, 98]:

1. Adım: EKG işaret kaydının bir dakikalık kısmının 7. seviyeden DD ayrıştırılmasıdır (Şekil 5.13). Bu ayrıştırma sonucunda QRS dalgaları R tepe konumlarının tespitinde kullanılacak işaretler belirlenir. Belirlenen bu işaretlerden biri D2 detay alt bandı işareti iken diğeri ise A7 yaklaşık alt bandı işaretinin orijinal EKG işaretinden çıkarılması ile elde edilen THSA- EKG işaretidir.

2. Adım: D2 detay alt bant işareti kullanılarak ardışık QRS dalgalarının R tepe konumlarının tespit edilmesidir. Bu adımda öncelikle D2 detay alt bant işareti için bir eşik değeri belirlenir. Literatürde eşik değerinin hesaplanması için farklı yaklaşımlar bulunmaktadır [88]. Bu çalışmada D2 işaretinin etkin değeri eşik değeri olarak seçilmiştir. 6000 örnekten oluşan D2 işaretinin eşik değerinin hesabı için kullanılan ifade aşağıda verilmektedir.

$$ED = 2 \cdot \sqrt{\frac{1}{6000} \sum_{n=1}^{6000} (D_2[n])^2} \quad (5.3)$$


Eşik değeri belirlenmesinin ardından, QRS dalgasının R tepesini belirlemeyi garantilemek için normal QRS dalgasının 2 katı genişliğinde olan 20 örneklik (200ms) bir pencere ile D2 işareti baştan sona taranır. Her bir pencereye ait maksimum değeri eşik değeri ile karşılaştırılır. Eğer maksimum değeri eşik değerden büyük ise bu maksimum değeri, konumu ile birlikte kaydedilir. Bu işlem D2 işaretinin ardışık ve birbiriyle örtüşmeyen 20

örnek genişliğindeki tüm olası kısımları (pencereleri) için tekrarlanır. Ayrıca bu işlemin tekrarı esnasında aynı QRS dalgasına ait birden fazla konum tespiti önünü geçebilmek için tespit edilen her iki ardışık konum arasındaki mesafeye bakılır. Eğer bu mesafe 20 örnek veya 20 örneğin altıda ise bu ardışık konumlardan genişliği daha büyük olanı ilgili QRS dalgasının R tepe konumu olarak seçilir. Böylece D2 detay işareti üzerindeki tüm QRS dalgaları R tepe konumları ardışık olarak belirlenmiş olur. Ancak, Orijinal EKG işaretinin dalgacık dönüşüm ayrışımının D2 detay işareti kullanılarak belirlenmiş olan bu konumlar, DD'nin aşağı-yukarı örnekleme yapısından kaynaklanan faz kaymaları sebebiyle hatalı olabilmektedir. Bu çalışmada DD'den kaynaklanan konum hatalarının genelde 1 ile 100 örnek (10 ile 100 ms) arasında değişebildiği görülmüştür. Oluşabilecek bu konum hatalarını minimize etmek amacıyla aşağıda verilen 3. adım işlemleri gerçekleştirilir.

3. Adım: Bu adımda öncelikle QRS dalgalarına ait 2. adımda belirlenmiş olan R tepe konumları, THSA- EKG işareti üzerine haritalanır. Daha sonra haritalanan her konumun 10 örnek (100 ms) sağ ve 10 örnek (100 ms) solu ile sınırlı pencereler içerisinde kalan THSA- EKG işaretine ait kısımların maksimum genliklerine ait konumlar belirlenir. Belirlenen bu konumlar EKG işareti üzerindeki QRS dalgalarının gerçek R tepe konumlarıdır. Böylelikle algoritmanın bu 3. adımıyla 1 dakikalık EKG kaydının ardışıl QRS dalgaları R tepe konumları saptanmış olur.


4. Adım: Bu adımda, THSA işareti üzerindeki ardışık QRS dalgalarının belirlenen sınırlar (R tepesini 5 örnek sağ ve 5 örnek solu ile sınırlı alan) içerisinde kalan alanları hesaplanır. Burada THSA işareti ayrık olduğu için hesaplanan her alan belirtilen sınırlar içerisinde kalan örneklerin (11 örnek) toplamı ile ifade edilir. Bu şekilde hesaplanan ardışık alanlar 1 dakikalık EKG kaydının ETS işaretine karşılık gelir.

5. Adım: Kişinin yaklaşık 8 saatlik süreden oluşan EKG kaydının tüm ardışık QRS dalgaları R tepe konumlarının tespiti ve tüm ardışık QRS dalgalarının belirlenen sınırlar içerisinde kalan alanlarının hesabı için yukarıda verilmiş olan 1- 4 adımları tekrarlanır. Bu sürecin sonunda hesaplanacak olan ardışık QRS dalgalarının belirlenen sınırlar içerisinde kalan alanları kişinin EKG kaydından elde edilen ETS işaretine karşılık gelir (Şekil 5.15).



Şekil 5.15. Yaklaşık 8 saat süreli bir EKG kaydından elde edilen ETS işareti.

6. Adım: Tespit edilen R tepe konumları kullanılarak ardışık R-R aralıkları hesaplanır. Hesaplanan bu aralıklar kişinin EKG kaydından elde edilen KHD işaretine karşılık gelir (Şekil 5.16).



Şekil 5.16. Yaklaşık 8 saat süreli bir EKG kaydından elde edilen KHD işareti.

Yukarıda verilmiş olan DD'ye dayalı algoritmanın 6. adımının sonunda kişi EKG kaydının tüm ardışık R-R aralıkları (KHD İşareti) ve tüm ardışık QRS dalgalarının belirlenen sınırlar içerisinde kalan alanları (ETS işareti) hesaplanmış olur. Bu şekilde hesaplan KHD ve ETS işaretlerine daha sonra her biri farklı bir işleve sahip 3 farklı işlem uygulanmıştır. Bu işlemler aşağıda verilmiştir:

1. Hesaplanan KHD işareti normal olmayan R-R aralıklar içerebilmektedir. KHD işaretindeki bu normal olmayan aralıklar, EKG kaydının aşırı gürültü içermesi dolayısıyla bazı QRS dalgalarının R tepe konumlarının yanlış tespit edilmiş olmasından kaynaklı olabildiği gibi EKG'nin sahte (spuriuos) ve kayıp (missed) QRS dalgalarından da

kaynaklanabilmektedir [41]. KHD işaretinin analizini güçleştiren bu tip aralıkları tercihen yok etmek gerekmektedir. Literatürde bu işlem için çeşitli yöntemler önerilmektedir [41, 51, 155]. Bu çalışmada, 0.5 saniyenin altındaki ve 1.5 saniyenin üzerindeki R-R aralıklar anormal olarak kabul edilip KHD işaretinden arındırılmıştır. Ayrıca bu anormal aralıkların karşılık geldiği alanlar da ETS işaretinden arındırılmıştır. Daha önceki bir çalışmada buna benzer bir uygulama verilmiştir [156].

2. Her biri yaklaşık 8 saat olan 60 EKG kaydının her birinden elde edilen KHD ve ETS işaretleri anormal atımlardan arındırıldıktan sonra kübik spline interpolasyon yöntemi ile örnek (nokta) sayıları 65536 olacak şekilde yeniden örneklenmişlerdir. Bu işlem öncesinde KHD işaretleri (60 KHD işareti) ve ETS işaretleri (60 ETS işareti) veri boyutu açısından birbirinden farklıdır. Bu durum çalışmanın ilerleyen kısımlarında kullanılacak özellik çıkarım yöntemlerinin bu işaretlere uygulanabilirliğini güçleştirdiğinden işaretler belirtilen biçimde tek tek yeniden örneklenmiş ve böylece veri boyuta açısından eşitlenmişlerdir. Yeniden örnekleme işleme için kübik spline interpolasyon yönteminin tercih edilmesinin sebebi ise diğer interpolasyon yöntemlerine göre kullanımının basit olması ve işaretlerin yüksek frekans bileşenlerini zayıflatmamasıdır [157].


3. Yeniden örnekleme işleminin ardından her KHD ve ETS işaretine normalizasyon işlemi uygulanmıştır. Normalizasyon, işaretleri kişiye özgü özelliklerden bağımsız kılabilmek için başvurulacak bir işlemdir. Burada KHD ve ETS işaretlerinin normalizasyonu işlemi için aşağıda verilen ifade kullanılmıştır.

$$X = \frac{x - \mu}{\sigma} \quad (5.4)$$


Burada, μ ve σ sırasıyla x işaretinin ortalama ve standart sapma değerleridir. X ise x işaretinin normalize edilmiş durumuna karşılık gelen işarettir. (5.4) ile gösterilen işlemin ETS ve KHD işaretlerini uygulanması ile bu işaretler, ortalamaları 0 ve standart sapmaları da 1 olacak biçimde normalize edilmiş olurlar.

Buraya kadar gerçekleştirilen tüm işlemler sonucunda her biri yaklaşık 8 saat olan 60 EKG kaydının (20'si sağlıklı kişilere ait 40 ise OUAS'lı hastalara ait EKG kayıtlarının) her birinin yeniden örnekleme ve normalize edilmiş KHD işareti ve ETS işareti elde edilmiş

olur. Örnek bir EKG kaydına ait KHD ve ETS işaretlerin yeniden örneklenmiş ve normalize edilmiş biçimleri sırasıyla Şekil 5.17’de ve Şekil 5.18’de verilmiştir.



Şekil 5.17. EKG kaydına ait örneklenmiş ve normalize edilmiş KHD işareti.



Şekil 5.18. EKG kaydına ait örneklenmiş ve normalize edilmiş ETS işareti.


5.2.3. KHD ve ETS İşaretlerinden Özellik Çıkarma

Çalışmanın bir önceki kısmını oluşturan ön-işleme sürecinde her EKG kaydının KHD ve ETS işaretleri elde edilmişti. Elde edilen bu KHD ve ETS işaretleri durağan olmayan işaretlerdir. Ayrıca KHD ve ETS işaretlerinin uzun süreli EKG kayıtlarından elde edilmesi bu işaretlerin veri boyutlarının yüksek olmasına neden olmaktadır. KHD ve ETS işaretlerinin durağan olmamaları ve veri boyutlarının yüksek olması örüntü tanıma sisteminde kullanılacak sınıflandırıcıların eğitim sürelerini artıracaktır. Aynı zamanda bu sınıflandırıcıların genelleme ve ayırıştırma yeteneklerini de azaltacaktır. Bu olumsuzlukları giderebilmek için ETS ve KHD işaretlerine uygun özellik çıkarım yöntemi uygulanarak

her işaret yeniden tanımlanmıştır. Bu çalışmada özellik çıkarım için iki farklı yöntem kullanılmıştır. ETS ve KHD işaretlerine uygulanan özellik çıkarım yöntemlerinden birincisi, DD ve entropi hesaplama tekniğine dayalı olan yöntemdir. Bu yöntemin sunumu ve KHD ve ETS işaretlerine uygulaması 5.2.3.1. alt başlığı altında verilmiştir. İkinci özellik çıkarım yöntemi ise DD, Welch GSY ve entropi hesaplama tekniğinin birlikte kullanıldığı yöntemdir. Bu yöntemin sunumu ve KHD ve ETS işaretlerine uygulaması da 5.2.3.2. alt başlığında verilmiştir. Yöntemlerin dayalı olduğu işaret işleme tekniklerinin teorik matematiksel alt yapısı bölüm 4.2’de verilmiştir.

5.2.3.1. Dalgacık Dönüşümünden Entropi Hesaplanması

KHD ve ETS işaret örüntülerinden özellik çıkarımı için kullanılan Dalgacık Dönüşümünden Entropi Hesaplama (DD-EH) ile özellik çıkarım yönteminin blok diyagramı Şekil 5.19’de verilmiştir.



Şekil 5.19. KHD ve ETS işaretleri için DD bileşenlerinin entropisi ile özellik çıkarımın blok diyagramı.


Blok diyagramın her aşamasında gerçekleştirilen işlemler ve bu işlemlerin KHD ve ETS işaretlerine uygulanması aşağıda sunulmuştur:

1. DD ile KHD ve ETS işaretlerinin alt bileşenlerine ayrıştırılması:


DD analizi ile işaret süresince var olan karakteristik frekans bileşenleri elde edilir. Bir işaretin DD ile analizinde uygun dalgacık tipinin seçimi ve ayrışım seviyelerinin sayısının tespiti önemlidir [108]. Bu çalışmada, her biri 65536 noktadan oluşan KHD ve ETS işaretlerinin DD ile analizi için Daubechies 4 (db4) dalgacık tipi kullanılmıştır. İşaretlerin ayrışım seviyelerinin sayısı ise 12 olarak belirlenmiştir. Kullanılan dalgacık tipinin seçiminde önceki çalışmalar referans alınmıştır [40]. İşaretlerin ayrışım seviyelerinin sayısı ise aşağıda verilen kritere göre belirlenmiştir [99].

$$\frac{n}{2^m} \geq 2N \quad (5.5)$$

Burada n (65536) işaretlerin nokta sayısıdır. $2N$ (16) seçilen dalgacık tipine bağlı olan ayrışım filtresinin bant genişliğidir. m (12) ise işaretlerin ayrışım seviyelerinin sayısıdır. Böylelikle DD-EH özellik çıkarma yönteminin bu aşamasında db4 kullanılarak her EKG kaydına ilişkin KHD ve ETS işaretlerinin her birinin 12. seviyeden DD ayrışımı gerçekleştirilmiştir. Bu ayrıştırma işlemi sonucunda her işaret, 12'si detay katsayıları (D_1 - D_{12}) ve 1'i de yaklaşık katsayısı (A_{12}) olmak üzere 13 alt bileşenine ayrıştırılmış olur. Şekil 5.20'de her biri farklı sınıfa ait 2 örnek EKG kaydının KHD işaretlerinin DD ayrıştırması verilmiştir. Şekil 5.21'de ise bu 2 kaydın ETS işaretlerinin DD ayrıştırması verilmiştir.



Şekil 5.20. (a) Normal ve (b) OUAS'lı KHD işaretlerinin 12. seviyeden DD'leri.



Şekil 5.21. (a) Normal ve (b) OUAS'lı ETS işaretlerinin 12. seviyeden DD'leri.

2. KHD ve ETS işaretlerine ait bileşenler için entropi hesaplaması:

Burada ise düzensizliğin ölçüsü olan entropi hesaplama tekniği kullanılarak her EKG kaydına ait KHD ve ETS işaretlerinin DD ayrıştırması ile elde edilen detay katsayı bileşenlerinin entropi değeri hesaplanmıştır. Bu işlem ile yüksek veri boyutlu detay katsayı bileşenlerinin her biri bir entropi değeri ile temsil edilmiş olunacağından KHD ve ETS işaretlerinin her biri de 12 veri uzunluğunda bir özellik vektörü ile temsil edilmiş olur.

Burada bu işlemi için norm entropi hesaplama tekniği kullanılmıştır. Bu tekniğin işaretlere ait detay katsayı bileşenlerine uygulama biçimi Denklem 5.6’da verildiği gibidir.

$$E_i = \sum_{n=1}^N |D_i[n]|^p, \quad i = 1, 2, \dots, 12 \quad (5.6)$$


Buradaki D_i , KHD veya ETS işaretinin i .seviyedeki detay katsayı bileşenidir. N (65536) katsayı bileşenlerinin veri boyutudur. p bu çalışmada 7/5 olarak seçilen sabit bir değerdir. E_i ise KHD veya ETS işaretinin i .seviyedeki detay katsayı bileşeninin norm entropi değeridir. Denklem 5.6’daki ifadenin her EKG kaydına ait KHD ve ETS işaretlerinin detay katsayı bileşenlerine uygulanması ile KHD işareti,

$$V_{\text{KHD}} = [E_1, E_2, \dots, E_{12}] \quad (5.7)$$


biçiminde veri boyutu 12 olan bir özellik vektörü ile betimlenirken ETS işareti ise,

$$V_{\text{ETS}} = [E_1, E_2, \dots, E_{12}] \quad (5.8)$$

biçiminde yine veri boyutu 12 olan bir özellik vektörü ile betimlenmiş olur. Şekil 5.22’de her biri farklı sınıfa ait 2 örnek EKG kaydının KHD işaretlerini betimleyen özellikler verilmiştir. Şekil 5.23’de ise bu 2 kaydın ETS işaretlerini betimleyen özellikler verilmiştir.




Şekil 5.22. (a) Normal ve (b) OUAS’lı KHD işaretlerinin DD-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.



Şekil 5.23. (a) Normal ve (b) OUAS'lı ETS işaretlerinin DD-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.

5.2.3.2. Dalgacık Dönüşümü ve Welch GSY ile Entropi Hesaplanması

KHD ve ETS işaret örüntülerinden özellik çıkarımı için kullanılan DD ve Welch GSY ile Entropi Hesaplanması (DD-WGSY-EH) yönteminin blok diyagramı Şekil 5.24'de verilmiştir.



Şekil 5.24. KHD ve ETS işaretleri için DD ve Welch GSY kestirimi entropileri ile özellik çıkarımın blok diyagramı.


Blok diyagramın her aşamasında gerçekleştirilen işlemler ve bu işlemlerin KHD ve ETS işaretlerine uygulanması aşağıda sunulmuştur:

1. DD ile KHD ve ETS işaretlerinin alt bileşenlerine ayrıştırılması:


DD-WGSY-EH özellik çıkarımı yönteminin bu ilk aşamasında gerçekleştirilen işlemler, bölüm 5.2.3.1’de verilmiş olan DD-EH özellik çıkarımı yönteminin ilk aşamasında gerçekleştirilen işlemlerle aynıdır. Yani, her EKG kaydına ait KHD ve ETS işaretlerinin her biri DD analizi ile 12’si detay katsayı bileşeni (D_1 - D_{12}) ve 1’i yaklaşık katsayı işareti (A_{12}) olmak üzere 13 alt bileşene ayrıştırılmıştır (Şekil 5.20 - 5.21).

2. KHD ve ETS işaretlerine ait bileşenlerin Welch yöntemi ile GSY kestirimi:

DD-WGSY-EH özellik çıkarımı yönteminin bu ikinci aşamasında KHD ve ETS işaretlerinin her birine ait detay katsayı bileşenlerinin (D_1 - D_{12}) frekans bölgesi bilgilerine ulaşmak için Welch yöntemi kullanılarak her katsayı işaretinin GSY’si hesaplanmıştır. Bölüm 4.2.3’de bahsedildiği gibi, bir işaretin Welch yöntemi ile GSY’si hesaplanırken; öncelikle işaret üst üste binmiş (overlapped) parçalara ayrılır, sonra her bir parça uygun bir pencere fonksiyonu ile pencerelenir, daha sonra pencerelenmiş her bir parçanın periyodogramı hesaplanır ve son olarak hesaplanmış periyodogramların ortalaması alınır [111]. Bu çalışmada KHD ve ETS işaretlerinin her birine ilişkin D_1 - D_{12} detay katsayı bileşenlerine Welch yöntemi uygulanırken, pencere fonksiyonu olarak 2048 noktalı Hanning pencere fonksiyonu kullanılmış ve parçaların üst üste binme oranı %50 (1024 örnek) olarak seçilmiştir. Dolayısıyla her bir katsayı bileşeni, %50 oranında örtüşen ve 2048 örnek uzunluğunda olan 63 ayrı parçaya ayrıştırılmıştır. Bu durumda her katsayı bileşenin welch yöntemiyle elde edilen GSY’si 1024 örnek uzunluğunda olmuştur. Şekil 5.25’de her biri farklı sınıfa ait 2 örnek EKG kaydının KHD işaretlerinin DD detay katsayılarına (D_1 - D_{12}) ilişkin Welch yöntemi ile elde edilen GSY’leri (P_{D1} - P_{D12}) görülmektedir. Şekil 5.26’da ise bu 2 kaydın ETS işaretlerinin DD detay katsayılarına (D_1 - D_{12}) ilişkin Welch yöntemi ile elde edilen GSY’leri (P_{D1} - P_{D12}) görülmektedir.



Şekil 5.25. (a) Normal ve (b) OUAS'lı KHD işaretlerinin DD katsayılarına ilişkin hesaplanan GSY'ler.



Şekil 5.26. (a) Normal ve (b) OUAS'ly ETS işaretlerinin DD katsayılarına ilişkin hesaplanan GSY'ler.

3. GSY kestirimi yapılan bileşenlerinin entropi hesaplaması:

DD-WGSY-EH özellik çıkarımı yönteminin bu son aşamasında ise düzensizliğin ölçüsü olan entropi hesaplama tekniği kullanılarak KHD ve ETS işaretlerinin DD detay katsayı bileşenlerinin Welch yöntemi ile elde edilen GSY'lerinin (P_{D1} - P_{D12}) entropi değeri hesaplanmıştır. Bu işlem ile yüksek veri boyutlu detay katsayı bileşenlerine ilişkin GSY'lerin her biri bir entropi değeri ile temsil edilmiş olunacağından KHD ve ETS

işaretlerinin her biri de 12 veri uzunluğunda bir özellik vektörü ile temsil edilmiş olur. Burada bu işlemi için norm entropi hesaplama tekniği kullanılmıştır. Bu tekniğin işaretlere ait detay katsayı bileşenlerinin GSY'lerine uygulama biçimi Denklem 5.9'da verildiği gibidir.

$$E_i = \sum_{n=1}^N |P_{D_i}[n]|^p, \quad i=1,2,...,12 \quad (5.9)$$


Burada P_{D_i} KHD veya ETS işaretinin i .seviyedeki detay katsayı bileşenine ilişkin GSY'dir. N (1025) katsayı bileşenlerine ilişkin GSY'lerin veri boyutudur. p bu çalışmada 7/5 olarak seçilen sabit bir değerdir. E_i ise KHD veya ETS işaretinin i .seviyedeki detay katsayı bileşenine ilişkin GSY'nin norm entropi değeridir. Denklem 5.9'daki ifadenin her EKG kaydına ait KHD ve ETS işaretlerinin detay katsayı bileşenlerine ilişkin GSY'lere uygulanması ile KHD işareti,

$$V_{KHD}=[E_1, E_2, ..., E_{12}] \quad (5.10)$$


biçiminde veri boyutu 12 olan bir özellik vektörü ile betimlenirken ETS işareti ise,

$$V_{ETS}=[E_1, E_2, ..., E_{12}] \quad (5.11)$$

biçiminde yine veri boyutu 12 olan bir özellik vektörü ile betimlenmiş olur. Şekil 5.27'de her biri farklı sınıfa ait 2 örnek EKG kaydının KHD işaretlerini betimleyen özellikler verilmiştir. Şekil 5.28'de ise bu 2 kaydın ETS işaretlerini betimleyen özellikleri verilmiştir.



Şekil 5.27. (a) Normal ve (b) OUAS'lı KHD işaretlerinin DD-WGSY-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.



Şekil 5.28. (a) Normal ve (b) OUAS'lı ETS işaretlerinin DD-WGSY-EH yöntemi ile elde edilen özelliklerinin grafiksel gösterimi.

5.2.4. EKG Kayıtlarından Türetilen KHD ve ETS İşaret Örüntülerini Sınıflandırma

Bölüm 5.2.2'de 40'ı OUAS hastası ve 20'si normal olan toplam 60 EKG kaydının her birine ilişkin KHD ve ETS işaretleri elde edilmiştir. Dolayısıyla her EKG kaydı biri KHD ve diğeri de ETS işareti olmak üzere 2 işaret ile temsil edilmiş olmaktadır. Bu işlemin ardından bölüm 5.2.3'de sunulduğu gibi DD-EH ve DD-WGSY-EH özellik çıkarım yöntemleri kullanılarak her KHD ve ETS işaretlerine ilişkin 2 farklı özellik vektörü elde edilmiştir. Böylece KHD ve ETS işaretleri, DD-EH ve DD-WGSY-EH özellik çıkarım yöntemleri kombinasyonlarından oluşturulan dört farklı özellik vektörü elde edilmiş olmaktadır. Ayrıca aynı özellik çıkarım yöntemi ile elde edilen özellik

vektörlerinin birleştirilmesi ile iki ayrı özellik vektörü daha elde edilmiştir. Böylece her EKG kaydına ilişkin 6 farklı özellik vektörü elde edilmiş olmaktadır.

Bu bölümde, EKG kayıtlarından elde edilmiş olan özellik vektörlerinin OUAS'lı durumu temsil etme performansı iki farklı sınıflandırıcı kullanılarak test edilmiştir. Kullanılan bu sınıflandırıcılardan biri YSA ve diğeri ise EKK-DVM dir. Bu çalışmada 6 farklı özellik vektörünün iki farklı sınıflandırıcı ile sınıflandırılması sonucu EKG kaydından OUAS'ın tespiti için 12 farklı örüntü sınıflandırma yaklaşımı yapılmıştır. Bu yaklaşımların her birinde kullanılan EKG kaydına ilişkin işaret türü, özellik çıkarım yöntemi ve sınıflandırıcı yöntemi Tablo 5.9 de verilmektedir.

Tablo 5.9. EKG'den OUAS tespitini yapan 12 farklı örüntü sınıflandırma yaklaşımının kullanılan EKG kaydına ilişkin işaret türü, özellik çıkarım yöntemi ve sınıflandırıcı yöntemine göre gösterimleri.

		Kullanılan EKG Kaydına İlişkin İşaret Türü	Kullanılan Özellik Çıkarım Yöntemi	Kullanılan Sınıflandırıcı yöntemi
OUAS’ın Tespitini Yapan Örüntü Sınıflandırma Yaklaşımları	1	KHD	DD-EH	YSA
	2	ETS		
	3	KHD + ETS		
	4	KHD	DD-WGSY-EH	
	5	ETS		
	6	KHD + ETS		
	7	KHD	DD-EH	EKK-DVM
	8	ETS		
	9	KHD + ETS		
	10	KHD	DD-WGSY-EH	
	11	ETS		
	12	KHD + ETS		

Tablo 5.9'de verilen her örüntü sınıflandırma yaklaşımında sınıflandırıcının güvenilirlik testi için k-katlı çapraz doğrulama (*k*-fold cross validation) testi kullanılmıştır [158]. k-katlı çapraz doğrulama testinde teste tabi tutulacak veri kümesi, k adet alt veri kümesine bölünür. Daha sonra bu alt veri kümelerinin k-1 tanesi sınıflandırıcının eğitiminde, geriye kalan diğer alt veri kümesi ise sınıflandırıcının testinde kullanılır. Belirtilen bu son işlem

biçimi tüm olası alt veri kümeleri sınıflandırıcının test işleminde kullanılıncaya kadar k defa tekrarlanır. Böylelikle sınıflandırılacak veri kümesinin hepsi test edilerek verinin tamamı hakkında sonuç elde edilir.

Bu çalışmada Tablo 5.9’de verilen sınıflandırma yaklaşımlarının her birinin OUAS tespitindeki etkinliğinin testi için 5- katlı çapraz doğrulama yöntemi kullanılmıştır. Çalışmada 40’ı OUAS’lı ve 20’si normal olmak üzere toplam 60 EKG kaydı olduğu için, 5-katlı çapraz doğrulama testinde kullanılan her bir alt veri kümesi 12 EKG kaydına (8’i OUAS’lı ve 4’ü Normal EKG kaydına) ait verileri içermektedir. Dolayısıyla 5 aşamadan oluşan testin her aşamasında 48 EKG kaydına ilişkin veriler sınıflandırıcının eğitimi için, 12 EKG kaydına ilişkin veriler ise sınıflandırıcının test edilmesi için kullanılmıştır.

Ayrıca her sınıflandırma yaklaşımının test performansı istatistiksel parametrelerin hesaplanması ile değerlendirilmiştir. Bu parametreler aşağıda verilmiştir:

$$\text{Doğruluk (Accuracy)} = \frac{GP + GN}{GP + YP + DN + YN} (\%) \quad (5.12)$$

$$\text{Kesinlik (Specificity)} = \frac{GN}{YP + GN} (\%) \quad (5.13)$$

$$\text{Duyarlılık (Sensitivity)} = \frac{GP}{GP + YN} (\%) \quad (5.14)$$

Buradaki GP , GN , YP ve YN de istatistiksel parametreler olup çalışmamız açısından aşağıda verildiği gibi tanımlanırlar:

Gerçek Pozitif (GP): OUAS hastası olgulara sınıflandırıcının da OUAS hastası dediği olgular.

Gerçek Negatif (GN): OUAS hastası olmayan olgulara sınıflandırıcının da OUAS hastası değil dediği olgular.

Yanlış Pozitif (YP): OUAS hastası olmayan olgulara sınıflandırıcının OUAS hastası dediği olgular.

Yanlış Negatif (YN): OUAS hastası olgulara sınıflandırıcının OUAS hastası değil dediği olgular.

Çalışmamız açısından tanımlanan bu istatistiksel parametreler aslında topluca konfüzyon matrisi (Confusion matrix) olarak adlandırılan bir tablo üzerinde gösterilirler [158]. Konfüzyon matrisinin çalışmamıza uyarlanmış biçiminin örneği Tablo 5.10’de verildiği gibidir.

Tablo 5.10. Konfüzyon matrisi.

Sınıflandırma Test Sonuçları	Gerçek Sonuçlar	
	OUAS	NORMAL
OUAS	GP	YP
NORMAL	YN	GN

Tablo 5.9’da verilmiş olan YSA tabanlı örüntü sınıflandırma yaklaşımları (1, 2, 3, 4, 5, 6) bölüm 5.2.4.1’de, EKK-DVM tabanlı örüntü sınıflandırma yaklaşımları (7, 8, 9, 10, 11, 12) ise bölüm 5.2.4.2’de sunulmaktadır.

5.2.4.1. Yapay Sinir Ağları Tabanlı Sınıflandırma

Tablo 5.9’daki YSA tabanlı ilk 6 örüntü sınıflandırma yaklaşımlarında kullanılan YSA sınıflandırıcı modeli için ÇKA modeli kullanılmıştır. Bu model YSA uygulamalarında en sık tercih edilen modeldir [99, 124]. Kullanılan YSA modelinin eğitim parametreleri ve yapısı Tablo 5.11’de verilmiştir. YSA modelinin ara katmanındaki yapay hücre sayısı, ara ve çıkış katmanındaki hücrelerin aktivasyon fonksiyonlarının türleri ve öğrenme oranı değeri, birkaç deneme ile en iyi başarımlar için seçilmiştir. Tablo 5.11’de verilen YSA tabanlı sınıflandırma yaklaşımlarının her birinin OUAS tespitindeki etkinliğinin testi için 5-katlı çapraz doğrulama testi kullanılmıştır. Bu teste göre her sınıflandırma yaklaşımının OUAS’ı tespit etmedeki başarımının konfüzyon matrisi ile gösterimi Tablo 5.12’de verildiği gibidir

Tablo 5.11. Kullanılan YSA modelinin yapısı ve eğitim parametreleri.

YSA yapısı	
YSA modeli	Çok katmanlı algılayıcı (ÇKA)
Katman sayısı	3
Katmanlardaki yapay hücre sayısı	Giriş : Özellik vektörü bileşen sayısı Ara : 10 Çıkış : 2
Başlangıç ağırlıkları ve eşik değerleri	Rastgele
Aktivasyon fonksiyonları	Logaritmik sigmoid
YSA eğitim parametreleri	
Öğrenme kuralı	Hata geriye yayma (Resilient)
Öğrenme oranı	0.01
Toplam karesel hata	0.00001

Tablo 5.12. YSA tabanlı her sınıflandırma yaklaşımının OUAS'ı tespit etmedeki başarımının konfüzyon matrisi ile gösterimi.

Sınıflandırma Yaklaşımı	Sınıflandırma Test Sonuçları	Gerçek Sonuçlar	
		OUAS	NORMAL
KHD / DD-EH / YSA	OUAS	39	1
	NORMAL	1	19
ETS / DD-EH / YSA	OUAS	37	3
	NORMAL	3	17
(KHD / DD-EH + ETS / DD-EH) / YSA	OUAS	38	0
	NORMAL	2	20
KHD / DD-WGSY-EH / YSA	OUAS	39	2
	NORMAL	1	18
ETS / DD-WGSY-EH / YSA	OUAS	37	4
	NORMAL	3	16
(KHD / DD-WGSY-EH + ETS / DD-WGSY-EH) / YSA	OUAS	39	1
	NORMAL	1	19

Tablo 5.12’de verilen konfüzyon matrisindeki sonuçların kullanılması ile her sınıflandırma yaklaşımının Denklem 5.12-14 ile ifade edilen istatistiksel parametreler hesabına göre test performansı sonuçları ise Tablo 5.13’de görüldüğü gibidir.

Tablo 5.13. YSA tabanlı her sınıflandırma yaklaşımının istatistiksel parametreler hesabına göre test performansı sonuçları.

Sınıflandırma Yaklaşımı	İstatistiksel Parametreler		
	Duyarlılık (%)	Kesinlik (%)	Doğruluk (%)
KHD / DD-EH / YSA	97.5	95	96.7
ETS / DD-EH / YSA	92.5	85	90
(KHD / DD-EH + ETS / DD-EH) / YSA	95	100	96.7
KHD / DD-WGSY-EH / YSA	97.5	95	96.7
ETS / DD-WGSY-EH / YSA	92.5	85	90
(KHD / DD-WGSY-EH + ETS / DD-WGSY-EH) / YSA	97.5	95	96.7

5.2.4.2. En Küçük Kareler Destek Vektör Makine Tabanlı Sınıflandırma

Daha önce Tablo 5.9’deki YSA tabanlı ilk 6 örüntü sınıflandırma yaklaşımlarının OUAS’ı tespit etmedeki uygulama sonuçları verilmişti. Burada ise Tablo 5.9’deki EKK-DVM tabanlı son 6 örüntü sınıflandırma yaklaşımlarının OUAS’ı tespit etmedeki uygulama sonuçları verilmektedir. Uygulamada sınıflandırıcı olarak kullanılan EKK-DVM’in eğitiminde çekirdek fonksiyonu tipi olarak daha önce Tablo 4.4’de verilmiş olan radyal tabanlı çekirdek fonksiyonu kullanılmıştır. Kullanılan çekirdek fonksiyonun genişlik parametresi olan σ ’nin değeri 100 ve sınıflandırıcının düzenleme parametresi olan C ’nin değeri ise 100 olarak belirlenmiştir. σ ve C parametrelerinin aldığı değerler göre EKK-DVM sınıflandırıcısının sınıflandırma performansı değişebilmektedir. Burada bu iki parametrenin aldığı değerler birkaç deneme ile en iyi performans için belirlenmiş değerlerdir. EKK-DVM tabanlı sınıflandırma yaklaşımlarının her birinin OUAS tespit etmedeki etkinliklerinin testi için 5-katlı çapraz doğrulama testi kullanılmıştır. Bu teste göre her sınıflandırma yaklaşımının OUAS’ı tespit etmedeki başarımının konfüzyon matrisi ile gösterimi Tablo 5.14’de verildiği gibidir.

Tablo 5.14. EKK-DVM tabanlı her sınıflandırma yaklaşımının OUAS'ı tespit etmedeki başarımının konfüzyon matrisi ile gösterimi.

Sınıflandırma Yaklaşımı	Sınıflandırma Test Sonuçları	Gerçek Sonuçlar	
		OUAS	NORMAL
KHD / DD-EH / EKK-DVM	OUAS	40	1
	NORMAL	0	19
ETS / DD-EH / EKK-DVM	OUAS	37	2
	NORMAL	3	18
(KHD / DD-EH + ETS / DD-EH) / EKK-DVM	OUAS	39	1
	NORMAL	1	19
KHD / DD-WGSY-EH / EKK-DVM	OUAS	40	1
	NORMAL	0	19
ETS / DD-WGSY-EH / EKK-DVM	OUAS	38	2
	NORMAL	2	18
(KHD / DD-WGSY-EH + ETS / DD-WGSY-EH) / EKK-DVM	OUAS	39	1
	NORMAL	1	19

Tablo 5.14'de verilen konfüzyon matrisindeki sonuçların kullanılması ile her sınıflandırma yaklaşımının Denklem 5.12-14 ile ifade edilen istatistiksel parametreler hesabına göre test performansı sonuçları ise Tablo 5.15'de görüldüğü gibidir.

Tablo 5.15. EKK-DVM tabanlı her sınıflandırma yaklaşımının istatistiksel parametreler hesabına göre test performansı sonuçları.

Sınıflandırma Yaklaşımı	İstatistiksel Parametreler		
	Duyarlılık (%)	Kesinlik (%)	Doğruluk (%)
KHD / DD-EH / EKK-DVM	100	95	98.3
ETS / DD-EH / EKK-DVM	92.5	90	91.7
(KHD / DD-EH + ETS / DD-EH) / EKK-DVM	97.5	95	96.7
KHD / DD-WGSY-EH / EKK-DVM	100	95	98.3
ETS / DD-WGSY-EH / EKK-DVM	95	90	93.3
(KHD / DD-WGSY-EH + ETS / DD-WGSY-EH) / EKK-DVM	97.5	95	96.7

6. SONUÇ ve DEĞERLENDİRME

Herhangi bir problemin çözümüne yönelik geliştirilecek bir otomatik örüntü tanıma sisteminin başarımı, büyük oranda örüntüyü betimlemek için kullanılan özellik çıkarım yöntemine bağlıdır. Ayrıca örüntü tanıma sistemin başarımı kullanılan sınıflandırma yöntemiyle de yakından ilişkilidir. Çünkü örüntünün çeşidi, örüntüden elde edilen özelliklerin yapısı ve boyutu, işlem süresi ve karmaşıklığı gibi faktörlere göre tercih edilmesi gereken sınıflandırma yöntemi farklılık gösterebilir. Bunlara ilaveten bazen bir otomatik örüntü tanıma sisteminin başarımının artırılması için örüntünün bir ön işlem sürecinden geçirilmesine de ihtiyaç duyulabilmektedir.

Yukarda belirtilen ifadeler bağlamında bu doktora çalışmasının temel amaçlarından biri, EEG işaret örüntüsünden kişinin uyanıklık seviyesini uyku, uyuklama ve uyanık olarak tespit edebilen, özellik çıkarım ve sınıflandırma birimlerinden oluşan, başarımı yüksek ve literatürdeki benzer çalışmalar ile kıyaslanabilir bir otomatik örüntü tanıma sistemi sunmaktır. Sunulan bu sistemin özellik çıkarım biriminde EEG işaretlerinin karakteristik özelliklerini ortaya çıkarabilmek için DD tabanlı iki çeşit özellik çıkarım yöntemi (DD-EH ve DD-WGSY-EH) kullanılmıştır. Bu yöntemlerin ilkinde (DD-EH) öncelikle durağan olamayan EEG işaretleri, DD ile zaman uzayında daha durağan 5 alt bileşenlerine ayrıştırılmıştır. Daha sonra bu alt bileşeler içerisinde uyanıklık seviyesinin tespitinde karakteristik özellikler taşıyan ve işaretin Teta, Alfa ve Beta alt bantlarına karşılık gelen her alt bileşenin entropi değeri hesaplanmıştır. Böylelikle veri uzunluğu 750 olan 5 sn'lik bir EEG işaret bölütü veri uzunluğu 3 olan bir özellik vektörü ile temsil edilmiştir. İkinci özellik çıkarım yönteminde (DD-WGSY-EH) ise EEG'nin DD analizi ile belirlenen alt bantların (Teta, Alfa, Beta) her birinin öncelikle Welch GSY kestirimi yapılmış ve ardından her alt banda ait spektral bilginin entropi değeri hesaplanmıştır. İlk özellik çıkarım yönteminde olduğu gibi bu özellik çıkarım yönteminde de EEG işaret bölütü veri uzunluğu 3 olan bir özellik vektörü ile temsil edilmiştir. İlk yöntem (DD-EH) ile elde edilmiş olan özellik vektörü bir anlamda işaretin zaman uzayındaki değişim bilgisini temsil ederken, ikinci yöntem (DD-WGSY-EH) ile elde edilmiş olan özellik vektörü ise işaretin spektral uzaydaki değişim bilgisini temsil eder. EEG'den uyanıklık seviyesinin tespitine yönelik sunulan sistemin sınıflandırma biriminde ise YSA, ANFIS ve EKK-DVM gibi farklı yapay zeka sınıflandırıcıları kullanılmıştır. Böylelikle sunulan

sistemin özellik çıkarım biriminde kullanılan iki çeşit özellik çıkarım yöntemi ile sınıflandırma biriminde kullanılan 3 çeşit sınıflandırıcı arasında oluşturulan ikili kombinasyonlar yardımı ile EEG'den uyanıklık seviyesinin tespiti için 6 farklı sınıflandırma yaklaşımı gerçekleştirilmiştir. Özellik çıkarım/sınıflandırıcı bileşenlerinden oluşan bu 6 sınıflandırma yaklaşımının her birinin EEG'den uyanıklık seviyesini tespit etmedeki test başarımları Tablo 6.1'de belirtildiği biçimde gerçekleştirilmiştir.

Tablo. 6.1. EEG'den uyanıklık seviyesini tespit eden 6 sınıflandırma yaklaşımının her birinin test veri seti üzerindeki başarımları.

		Toplam Doğruluk Başarımları (%)
Özellik Çıkarım / Sınıflandırıcı Yöntemleri	DD-EH / YSA	91.1
	DD-WGSY-EH / YSA	96.1
	DD-EH / ANFIS	91.7
	DD-WGSY-EH / ANFIS	98.3
	DD-EH / EKK-DVM	88.3
	DD-WGSY-EH / EKK-DVM	93.9

Bu tez çalışmanın diğer bir temel amacı ise kişiye ait tüm EKG kaydından kişinin OUAS hastası olup olmadığını tespit eden, başarımları yüksek ve literatürdeki benzer çalışmalar ile kıyaslanabilir bir otomatik örüntü tanıma sistemi sunmaktır. Sunulan sistem ön işlem, özellik çıkarım ve sınıflandırma olmak üzere 3 temel birimden oluşmaktadır. Ön işlem birimi, geliştirilen DD tabanlı bir algoritma yardımıyla EKG kayıtlarından KHD ve ETS işaretlerinin hesaplandığı birimdir. Özellik çıkarım birimi ise EKG kayıtlarından hesaplanan yüksek veri boyutlu KHD ve ETS işaretlerinin her birinin daha düşük boyutlu karakteristik bilgilerinin ortaya çıkarıldığı birimdir. Bu işlem için biri DD dönüşümü ve entropi hesaplama tekniğinin birleşiminden oluşan (DD-EH), bir diğeri ise DD dönüşümü, Welch GSY kestirimi ve entropi hesaplama tekniğinin birleşiminden oluşan (DD-WGSY-EH) iki çeşit özellik çıkarım yöntemi kullanılmıştır. DD-EH özellik çıkarım yöntemiyle işaretler öncelikle DD ile 12. seviyeden alt bantlarına ayrıştırılmış ve ardından her detay (D1-D12) alt bantın entropi değeri hesaplanmıştır. Böylelikle her biri 65536 nokta veri

uzunluğunda olan KHD ve ETS işaretlerine uygulanan bu özellik çıkarım yöntemi ile her bir işaret veri uzunluğu 12 olan birer özellik vektörü ile temsil edilmiştir. DD-WGSY-EH özellik çıkarım yönteminde ise benzer şekilde öncelikle işaretler DD ile alt bantlarına ayrıştırılmış daha sonra işaretlere ilişkin detay alt banların her birinin Welch GSY kestirimi yapılmış ve daha sonra da her alt banda ait spektrum bilgisinin entropi değeri hesaplanmıştır. Bir önceki özellik çıkarım yönteminde olduğu gibi bu özellik çıkarım yönteminin KHD ve ETS işaretlerine uygulanması ile yine her bir işaret veri uzunluğu 12 olan birer özellik vektörleri ile temsil edilmiştir. Sunulan sistemin ön işlem ve özellik çıkarım birimlerinde kullanılan algoritmalar neticesinde kişiye ait tüm EKG kaydı 6 farklı özellik vektörü ile temsil edilmiş olmaktadır. Bunlar KHD'nin DD-EH ve DD-WGSY-EH özellik çıkarım yöntemleri ile elde edilen 2 özellik vektörü, ETS'nin DD-EH ve DD-WGSY-EH özellik çıkarım yöntemleri ile elde edilen 2 özellik vektörü, KHD ve ETS'nin DD-EH özellik çıkarım yöntemiyle elde edilen özelliklerinin birleşiminden oluşan özellik vektörü ve son olarak KHD ve ETS'nin DD-WGSY-EH özellik çıkarım yöntemi ile elde edilen özelliklerinin birleşiminden oluşan özellik vektörüdür. EKG kaydına ait bu özellik vektörlerinin her biri üzerinden kişinin OUAS hastası olup olmadığının tespiti için sunulan sistemin sınıflandırma biriminde ise yapay zeka tekniğinin iki farklı klasmanında yer alan YSA ve EKK-DVM sınıflandırıcıları kullanılmıştır. Böylelikle sunulan bu sistemin ön işlem ve özellik çıkarım birimlerinde kullanılan algoritmalar ile EKG kaydı 6 ayrı özellik vektörü ile temsil edilmiş ve her özellik vektörü üzerinden EKG'nin OUAS hastası olup olmadığının tespiti için ise 2 ayrı sınıflandırıcı kullanılmak sureti ile 12 ayrı sınıflandırma yaklaşımı gerçekleştirilmiştir. 12 sınıflandırma yaklaşımının her birinin etkinliğinin belirlenmesi için 5 katlı çarpaz doğrulama testi kullanılmıştır. Bu sınıflandırma yaklaşımlarının her birinin test başarımının yüzde olarak doğruluk sonuçları ise Tablo 6.2'de karşılaştırmalı olarak verilmiştir.

Bu çalışmada gerek EEG'den uyanıklık seviyesinin tespitine yönelik ve gerekse EKG kayıtlarından kişinin OUAS hastası olup olmadığına yönelik sunulmuş olan sistemlerin sonuçlarının değerlendirilmesi ise aşağıda verilmiştir.

Tablo. 6.2. EKG'den kişinin OUAS hastası olup olmadığını tespit eden 12 sınıflandırma yaklaşımının her birinin test veri seti üzerindeki başarımları.

		Toplam Doğruluk Başarımları (%)
Örüntü Sınıflandırma Yaklaşımları	KHD / DD-EH / YSA	96.7
	ETS / DD-EH / YSA	90
	(KHD / DD-EH + ETS / DD-EH) / YSA	96.7
	KHD / DD-WGSY-EH / YSA	96.7
	ETS / DD-WGSY-EH / YSA	90
	(KHD / DD-WGSY-EH + ETS / DD-WGSY-EH) / YSA	96.7
	KHD / DD-EH / EKK-DVM	98.3
	ETS / DD-EH / EKK-DVM	91.7
	(KHD / DD-EH + ETS / DD-EH) / EKK-DVM	96.7
	KHD / DD-WGSY-EH / EKK-DVM	98.3
	ETS / DD-WGSY-EH / EKK-DVM	93.3
	(KHD / DD-WGSY-EH + ETS / DD-WGSY-EH) / EKK-DVM	96.7

6.1. Sonuçların Değerlendirilmesi

Tez çalışmasının temel amaçlarından birini oluşturan EEG işaretinden uyanıklık seviyesine tespitine yönelik olarak sunulan otomatik örüntü tanıma sistemine ilişkin elde edilen sonuçların genel değerlendirilmesi aşağıda sunulmuştur.

- EEG'den uyanıklık seviyesinin otomatik tespitine yönelik sunulan sistemin özellik çıkarım biriminde kullanılan DD tabanlı DD-EH ve DD-WGSY-EH özellik çıkarım yöntemleri ile EEG işareti veri boyutları düşük iki farklı özellik vektörü ile temsil edilmiştir. Kullanılan DD-EH özellik çıkarım yöntemi ile EEG işareti karakteristik önemde olan alt bileşenlerinin her birinin zaman uzayında hesaplanan entropi değerleri ile temsil edilmiştir. Kullanılan DD-WGSY-EH özellik çıkarım yönteminde ise EEG işareti alt bileşenlerinin her birinin spektral uzayda hesaplanan entropi değerleri ile temsil edilmiştir. Böylelikle sunulan sistemin özellik çıkarım biriminde kullanılan bu iki özellik çıkarım yöntemi ile EEG işaretinden uyanıklık seviyesinin tespit edebilirliği, hem zaman uzayındaki değişim bilgisi

perspektifinden hem de frekans uzayındaki deęişim bilgisi perspektifinden incelenmiştir. Ayrıca sunulan sistemin sınıflandırma biriminde kullanılan 3 farklı sınıflandırıcı (YSA, ANFIS ve EKK-DVM) ile EEG işaretinden uyanıklık seviyesinin tespit edilebilirlik başarımının kullanılan sınıflandırıcı türü ile hangi oranda ilişkili olduđu gösterilmiştir.

- Sunulan sistemin özellik çıkarım biriminde kullanılan DD-EH ve DD-WGSY-EH özellik çıkarım yöntemlerinin her birinin güvenilirliđi sınıflandırma biriminde kullanılan YSA, ANFIS ve EKK-DVM sınıflandırıcılarının her biri üzerinde ayrı ayrı test edilmiştir. Bu testlerin her birinin toplam doğruluk olarak ifade edilen başarımları sonuçları topluca Tablo 6.1’de verilmiştir. Elde edilen bu başarımlara göre kullanılan özellik çıkarım yöntemleri karşılaştırıldığında DD-WGSY-EH’nin DD-EH’den daha güvenilir bir özellik çıkarım yöntemi olduđu açıkça görülebilmektedir. Buradan da EEG işaretinin frekans uzayındaki deęişim bilgisinin zaman uzayındaki deęişim bilgisine göre uyanıklık seviyesini tespit etmede daha belirleyici rol oynadıđı sonucuna varılmıştır.
- Tablo 1’de verilen başarımları aynı özellik çıkarım yöntemiyle birlikte kullanılan farklı türdeki sınıflandırıcılar açısından karşılaştırıldığında ise EEG’den uyanıklık seviyesinin tespit edilebilirliğinin kullanılan sınıflandırıcı türü ile de yakından ilişkili olduđu görülebilmektedir. Örneđin DD-WGSY-EH özellik çıkarım yöntemiyle sınıflandırma biriminde kullanılan 3 farklı sınıflandırıcı arasında oluşturulan DD-WGSY-EH/YSA, DD-WGSY-EH/ANFIS ve DD-WGSY-EH/EKK-DVM ikili kombinasyonların uyanıklık seviyesini tespit etmedeki başarımları sırasıyla %96.1, %98.3 ve %93.9 olarak gerçekleşmiştir. Bu sonuçlar göre ANFIS sınıflandırıcısıyla %98.3’lük en iyi sınıflandırma başarımları sağlanırken, EKK-DVM sınıflandırıcısıyla ise %93.9’luk en kötü sınıflandırma başarımları sağlanmıştır. Yine bu çalışmada sınıflandırıcılar açısından gözlemlenen diđer bir önemli sonuç ise sınıflandırıcıların eğitim sürecinin hızına ilişkindir. Bu açıdan sınıflandırıcıların başarımları toplam doğruluk olarak belirtilen başarımların tam tersi biçiminde gerçekleşmiştir. Yani EKK-DVM’nin eğitimi en hızlı biçimde gerçekleşirken ANFIS tabanlı sınıflandırıcının eğitimi ise en yavaş biçimde gerçekleşmiştir.

- EEG'den uyanıklık seviyesinin otomatik tespiti yönelik literatürde de benzer bazı çalışmalar yapılmıştır [19, 28, 29, 31, 32]. Mevcut çalışmayı literatürdeki bu benzer çalışmalar ile birkaç yönden kıyaslamak mümkündür. Bunlardan en önemlisi diğer benzer çalışmaların aksine bu çalışmada sunulan sistem ile EEG işaretinden uyanıklık seviyesinin tespit edilebilirliğine çok daha geniş perspektiften bakabilme imkanı sağlanmasıdır. Çünkü daha önceki çalışmalar EEG'den uyanıklık seviyesinin tespit edilebilirliğini, bu işaretin DD analizi ile elde edilen karakteristik alt bileşenlerinin ya zaman uzayındaki değişim bilgisi perspektifinden [28, 29, 31, 32] ya da bu bileşenlerin spektral uzaydaki değişim bilgisi perspektifinden [19] incelemişlerdir. Oysa bu çalışmada kullanılan DD-EH ve DD-WGSY-EH özellik çıkarım algoritmaları yardımıyla EEG'ye bu iki bilgi perspektifinden ayrı ayrı bakılarak hangi bilginin uyanıklık seviyesini tespit etmede daha etkin olabileceği incelenmiştir. Ayrıca benzer çalışmaların aksine özellik çıkarım algoritmalarındaki entropi hesaplama tekniği ile işaretin gerek zaman bilgisi ve gerekse spektral bilgisi çok daha düşük boyutlu veri ile temsil edilmiştir. Bu da sistemin sınıflandırma biriminde kullanılan sınıflandırıcıların işlem yükünü büyük oranda azaltmıştır. Yine bu çalışmayı diğer benzer çalışmalardan farklı kılan, işaretin elde edilmiş olan gerek zaman bilgisinin ve gerekse spektral bilgisinin her birinin güvenilirliği YSA, ANFIS ve EKK-DVM gibi 3 farklı sınıflandırıcı üzerinde ayrı ayrı test edilmiş olmasıdır. Bu tarz bir yaklaşım ile hem işaretin hangi bilgisinin ve hem de bu bilginin hangi sınıflandırıcı üzerinden uyanıklık seviyesini uyanık, uyuklama ve uyku olarak tespit etmede daha başarılı olabileceği gösterilmiştir (Tablo 6.1). Ayrıca bu çalışmanın diğer bir önemli farkı ANFIS ve EKK-DVM'nin EEG'den uyanıklık seviyesinin tespitinde sınıflandırıcı olarak kullanımlarına ilk defa bu çalışmada yer verilmesidir.

Tez çalışmasının bir diğer temel amacını oluşturan EKG kaydından kişinin OUAS hastası olup olmadığının tespitine yönelik olarak sunulan otomatik örüntü tanıma sistemine ilişkin elde edilen sonuçların genel değerlendirilmesi ise aşağıda verilmiştir.

- Daha önceden de ifade edildiği üzere EKG kaydından kişinin OUAS hastası olup olmadığının otomatik örüntü tanıma sistemi ile tespiti için 12 farklı sınıflandırma yaklaşımı gerçekleştirilmiştir (Tablo 6.2). Böylece, EKG kaydından OUAS

hastalığının tespitinde kullanılacak otomatik örüntü tanıma sistemine ait temel birimler için farklı yöntemler kullanılmasının sınıflandırma işleminin başarımlarını performansları üzerindeki etkileri incelenmiştir.

- Sunulan otomatik örüntü tanıma sisteminin başarımlarını kullanılan KHD ve ETS işaretleri üzerinden incelendiğinde KHD işaretinin ETS işaretine göre OUAS'ı tespit etmede daha belirleyici bir rol oynadığı görülmüştür. **Tablo 6.2'den** de görüleceği gibi ETS işareti üzerinden en iyi doğruluk başarımları % 93.3 iken KHD işareti üzerinden en iyi doğruluk başarımları ise %98.3'dür. Bu sonuçlar literatürdeki benzer çalışmaları destekler niteliktedir [50, 51]. Ayrıca bu sonuçlar örüntü tanıma sisteminin ön işlem birimi için önerilen DD tabanlı algoritmanın EKG kaydındaki QRS dalgası R tepelerini belirleme yeteneğinin yüksek olduğunu da göstermektedir. Çünkü bu çalışmada EKG'den KHD ve ETS işaretlerinin hesaplanması bu R tepeleri referans alınarak hesaplanmıştır.
- Sunulan otomatik örüntü tanıma sisteminin başarımlarına özellik çıkarım biriminde kullanılan DD-WGSY-EH ve DD-EH özellik çıkarım yöntemleri açısından bakıldığında ise her iki özellik çıkarım yönteminin de OUAS'ın tespitinde başarıyla kullanılabileceği görülmüştür. Bu iki özellik çıkarım yöntemiyle EKG'dan hesaplanan KHD ve ETS işaretlerinin her biri çok daha düşük boyutlu iki farklı özellik vektörü ile temsil edilmek suretiyle her iki işaretin OUAS hastalığını tespit etmedeki etkinlikleri iki farklı perspektiften incelenmiştir. **Tablo 6.2'den** de görüleceği gibi özellikle KHD işaretinin gerek DD-EH ve gerekse DD-WGSY-EH özellik çıkarım yöntemleri üzerinden OUAS hastalığını tespit etmedeki toplam doğruluk başarımları YSA sınıflandırıcısı ile % 96.7 olarak gerçekleştirirken EKK-DVM ile % 98.3 olarak gerçekleştirilmiştir. ETS işaretinin aynı özellik çıkarım yöntemleri üzerinden OUAS'ı tespit etmedeki doğruluk başarımları daha düşük olarak gerçekleştirilmiştir.
- Sunulan otomatik örüntü tanıma sisteminin başarımlarını sınıflandırma biriminde kullanılan YSA ve EKK-DVM sınıflandırıcıları açısından incelendiğinde ise genelde EKK-DVM sınıflandırıcısının doğruluk başarımlarının YSA sınıflandırıcısının doğruluk başarımlarından daha yüksek olduğu

görülmüştür. Tablo 6.2’den de görüleceği üzere YSA tabanlı ilk 6 sınıflandırma yaklaşımlarının doğruluk başarımları %90 ile %96.3 arasında değişirken EKK-DVM tabanlı son 6 sınıflandırma yaklaşımının doğruluk başarımları ise %91.7 ile %98.3 arasında değişmektedir. Ayrıca bu çalışmada gözlemlenen diğer bir önemli sonuç ise işlem hızı açısından EKK-DVM sınıflandırıcısının YSA sınıflandırıcısından daha iyi bir performans göstermiş olmasıdır. Dolayısıyla bu çalışma kapsamında sınıflandırıcıların gerek doğruluk başarımları ve gerekse işlem hızı performansları göz önüne alındığında EKK-DVM’nin OUAS tespitinde daha etkin olabileceği gösterilmiştir.

- Bu tez çalışmasında olduğu gibi tüm EKG kaydından kişinin OUAS hastası olup olmadığının otomatik tespitine yönelik literatürde de benzer bazı çalışmalar yapılmıştır [49-51]. Benzer çalışmalardan ikisi [49, 50] bu tez çalışmasında kullanılan aynı EKG veri bankasını kullanırken diğeri [51] ise farklı EKG veri bankasını kullanmıştır. Literatürdeki bu çalışmaların tümünün ortak özelliği EKG’den KHD veya ETS işaretlerinin hesaplanması için referans alınacak QRS dalgasının R tepelerini belirlemek için sayısal filtre tabanlı hazır bir algoritma [91] kullanmışlardır. Bu tez çalışmasında aynı işlem için hazır bir algoritma kullanmak yerine detayları bölüm 5.2.2.2’de verilmiş olan DD tabanlı bir algoritma geliştirilmiştir [97, 98]. Yine literatürdeki çalışmalarda [50, 51] kullanılan sınıflandırıcının geneleme yeteneğini artırabilmek için bir özellik çıkarım algoritması ile beraber ayrıca bir özellik seçme algoritması da kullanılmıştır. Oysa bu tez çalışmasında ayrıca bir özellik seçme algoritması kullanılmamasına rağmen sınıflandırıcıların OUAS’ı tespit etmedeki başarımları literatürdeki bu benzer çalışmalarla kıyaslanabilir düzeyde gerçekleşmiştir. Yine literatürdeki benzer çalışmalardan farklı olarak bu çalışmada sınıflandırıcı olarak YSA ve EKK-DVM sınıflandırıcıları kullanılmıştır. Ayrıca EKK-DVM’nin EKG kaydından OUAS’ın tespitinde sınıflandırıcı olarak kullanımına ilk defa bu çalışmada yer verilmiştir.

6.2. Öneriler

- Ulaştırma ve endüstriyel alanlarında, aşırı dikkat isteyen, uzun süreli ve monoton birçok iş kolunda meydana gelen kazaların bir kısmının uyuklamadan

kaynaklandığı bilinmektedir. Bu tez çalışmasında EEG'den uyanıklık seviyesinin otomatik tespiti için önerilen örüntü tanıma sisteminin, uyuklamadan kaynaklı bu tür kazaların önüne geçebilecek bir online uyarı sisteminin geliştirilmesine zemin oluşturabileceği düşünülmektedir.

- EKG kaydından OUAS hastalığının otomatik tespitine yönelik sunulan sistemin başarımlı performansı literatürdeki benzer çalışmalarla kıyaslanabilir düzeyde gerçekleşmiştir. Dolayısıyla sunulan sistemin taşınabilir portatif bir cihaz (holter gibi) ile kullanılmasının OUAS şüphelisi kişinin ön tanısına ev ortamında imkan sağlayabileceği düşünülmektedir.
- EKG kaydından hesaplanabilen KHD işaretinin bazı kardiyak aritmiler için kendine has karakteristik özellikler sergilediğı bilinmektedir. Bu açıdan bakıldığında ise OUAS'ın tespiti için sunulan sistemin ön işlem ve özellik çıkarm birimindeki algoritmaların bu tür aritmilerin değerlendirilmesine de uyarlanabileceğı düşünülmektedir.

KAYNAKLAR

- [1] American Academy of Sleep Medicine, 2005. Sleep related movement disorders. In: Sateia MJ, ed. The international classification of sleep disorders: diagnostic and coding manual. 2nd ed. Westchester Illinois: *American Academy of Sleep Medicine*.
- [2] Amer. Acad. Sleep Med. Task Force, 1999. Sleep-related breathing disorders in adults: Recommendations for syndrome definition and measurement techniques in clinical research, *Sleep*, 22, 667–689.
- [3] Young, T., Patla, M., Dempsey, J., Skatrud, J., Weber, S. and Badr, S., 1993. The occurrence of sleep-disordered breathing among middle-aged adults, *The New England Journal of Medicine*, 328, 1230-1235.
- [4] Coleman, J., 1999. Complications of snoring, upper airway resistance syndrome and obstructive sleep apnoea syndrome in adults, *Otolaryngologic Clinics of North America*, 32, 223-234.
- [5] Nieto, F.J., Young, T.B., Lind, B.K., Shahar, E., Samet, J.M., Redline, S., D'Agostino, R.B., Newman, A.B., Lebowitz, M.D. and Pickering, T.G., 2000. Association of sleep-disordered breathing, sleep apnea, and hypertension in a large community-based study, *Journal of the American Medical Association*, 283, 1829-1836.
- [6] Young, T., Peppard, P., Palta, M., Hla, K.M., Finn, L., Morgan, B. and Skatrud, J., 1997. Population-based study of sleep-disordered breathing as a risk factor for hypertension, *Archives of Internal Medicine*, 157, 1746-1752.
- [7] Lattimore, J.D., Celermajer, D.S. and Wilcox, I., 2003. Obstructive Sleep Apnea and Cardiovascular Disease, *Journal of the American College of Cardiology*, 41, 1429-1437.
- [8] Whitney, C.W., Gottlieb, D.J., Redline, S., Norman, R.G., Dodge, R.R., Shahar, E., Surovec, S. and Nieto, F.J., 1998. Reliability of scoring respiratory disturbance indices and sleep staging, *Sleep*, 21, 749–757.
- [9] Patil, S.P., Schneider, H, Schwartz, A.R. and Smith, P.L., 2007. Adult Obstructive Sleep Apnea Pathophysiology and Diagnosis, *Chest*, 132, 325-337.
- [10] Köktürk, O., 2000. Solunumsal uyku bozukluklarında tanı yaklaşımları. *Solunumsal uyku bozuklukları kursu Toraks Derneği Ulusal Akciğer Sağlığı Kongresi*, Antalya.
- [11] Conradt, R., Brandenburg, U., Penzel, T., Hasan, J., Varri, A. and Peter, J.H., 1999. Vigilance transitions in reaction time test: A method of describing the state of alertness more objectively, *Clinical Neurophysiology*, 110, 1499–1509.

- [12] Ogilvie, R.D., 2001. The process of falling asleep, *Sleep Medicine Reviews*, 5, 247-270.
- [13] Dinges, D., 1995. An overview of sleepiness and accidents, *J. Sleep Res.*, 4, 4–14.
- [14] Lyznicki, J.M., Doege, T.C., Davis, R.M., Williams, M.A., 1998. Sleepiness, driving, and motor vehicle crashes, *J. Am. Med. Assoc.*, 279, 1908–1913.
- [15] Rechtschaffen A, and Kales A., 1968. A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects, Public Health Service, US Government Printing Office, Washington.
- [16] Hori, T., Hayashi, M., Morikawa, T., 1994. Topographic EEG changes and the hypnagogic experience, In: Ogilvie, R.D., Harsh, J.R. (Eds.), *Sleep Onset: Normal and Abnormal Processes*, American Psychological Association, Washington.
- [17] Santamaria, J. and Chiappa K. H., 1987. The EEG of drowsiness in normal adults, *J. Clin. Neurophysiol*, 4, 327–382.
- [18] Vuckovic, A., Radivojevic, V., Chen, A.C.N., Popovic, D., 2002. Automatic recognition of alertness and drowsiness from EEG by an artificial neural network, *Med. Eng. Phys.*, 24,349–360.
- [19] Kiymik, M.K., Akin, M. and Subasi, A., 2004. Automatic recognition of alertness level by using wavelet transform and artificial neural network. *Journal of Neuroscience Methods*, 139, 231–240.
- [20] Makeig, S., Jung, T.P. and Sejnowski, T.J., 1996. Using feedforward neural Networks to monitor alertness from changes in EEG correlation and coherence, In: *Advances in neural information processing systems*, Cambridge, MA: MIT Pres, 8, 931–937.
- [21] Jung, T.P., Makeig, S., Stensmo, M. and Sejnowski, T.J., 1997. Estimating alertness from the EEG power spectrum, *IEEE Transactions on Biomedical Engineering*, 44, 60–69.
- [22] Gevins, A., Smith, M.E., 1999. Detecting transient cognitive impairment with EEG pattern recognition methods, *Aviation Space and Environment Medicine* 70, 1018–1024.
- [23] Ben Khalifa, K., Bedoui, M.H., Dogui, M. and Alexandre, F., 2004. Alertness states classification by SOM and LVQ neural Networks, *International Journal of Information Technology*, 3, 131-134.
- [24] Yeo, M. V.M., Li, X., Shen, K. and Wilder-Smith, E. P. V., 2009. Can SVM be used for automatic EEG detection of drowsiness during car driving?, *Safety Science*, 47,115–124.

- [25] Subasi, A., 2005a. Application of classical and model-based spectral methods to describe the state of alertness in EEG, *Journal of Medical Systems*, 29, 473- 486.
- [26] Pan, J., Ren, Q.S. and Lu, H.T., 2010. Vigilance analysis based on fractal features of EEG signals, *International Symposium on Computer, Communication, Control and Automation*, Tainan, Taiwan, May 5-7.
- [27] Wilson, B.J. and Bracewell, T.D., 2000. Alertness Monitor Using Neural Networks for EEG Analysis, *Proceedings of the IEEE Signal Processing Society Workshop on Neural Networks for Signal Processing X*, 2, 814-820.
- [28] Subasi, A., 2005b. Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients, *Expert Systems with Applications*, 28, 701–711.
- [29] Subasi, A., Kiyimik, M. K., Akin, M., and Eroglu, O., 2005c. Automatic recognition of vigilance state by using a wavelet-based artificial neural network, *Neural Computing and Applications*, 14, 45–55.
- [30] Ouyang, T., Lu, H.T. and Lu, B., 2010. Vigilance analysis based on EEG signals: Seeking for suitable features, *Journal of Biological Systems*, 18, 81-99.
- [31] Akin, M., Kurt, M.B., Sezgin, N. And Bayram, M., 2008. Estimating vigilance level by using EEG and EMG signals, *Neural Computing and Applications*, 17, 227–236.
- [32] Kurt, M.B., Sezgin, N., Akin, M., Kirbas, G. And Bayram, M., 2009. The ANN-based computing of drowsy level, *Expert Systems with Applications*, 36, 2534–2542.
- [33] Guilleminault, C., Connolly, S.J., Winkle, R., Melvin, K. and Tilkian, A., 1984. Cyclical variation of the heart rate in sleep apnoea syndrome. Mechanisms and usefulness of 24h electrocardiography as a screening technique, *Lancet*, 321, 126–131.
- [34] Penzel, T., Amend, G., Meinzer, K., Peter, J.H. and von Wichert, P., 1990. Mesam: a heart rate and snoring recorder for detection of obstructive sleep apnoea, *Sleep* 13, 175–182.
- [35] Hilton, M.F., Bates, R.A., Godfrey K.R., Chappell, M.J. and R. M. Cayton R.M., 1999. Evaluation of frequency and time-frequency spectral analysis of heart rate variability as a diagnostic marker of the sleep apnoea syndrome, *Med. Biol. Eng. Comput.*, 37, 760–769.
- [36] Roche, F., Gaspoz, J.M., Court-Fortune, I., Minini, P., Pichot, V., Duverney, D., Costes, F., Lacour, J.R. and Barthelemy J.C., 1999. Screening of obstructive sleep apnoea syndrome by heart rate variability analysis, *Circulation*, 100, 1411–1415.

- [37] Moody, G.B., Mark, R.G., Zoccola, A. and Mantero, S., 1986. Clinical validation of the ECG-derived respiration (EDR) technique, *Comput. Cardiol.*, 13, 507–510.
- [38] Travaglini, A., Lamberti, C., Debie, J and Ferri, M., 1998. Respiratory signal derived from eight-lead ECG, *Comput. Cardiol.*, 25, 65–68.
- [39] Penzel, T., McNames, J., de Chazal, P., Raymond, B., Murray, A. and Moody, G., 2002. Systematic comparison of different algorithms for apnoea detection based on ECG recordings, *Med. Biol. Eng. Comp.*, 40, 402–407.
- [40] Roche, F., Pichot, V., Sforza, E., Court-Fortune, I., Duverney, D., Costes, F., Garet, M. and Barthelemy, J-C., 2003. Predicting sleep apnoea syndrome from heart period: A time–frequency wavelet analysis, *Eur. Respir. J.*, 22, 937–942.
- [41] de Chazal, P, Heneghan, C., Sheridan, E., Reilly, R.B., Nolan, P. and O’Malley, M., 2003. Automated processing of the single lead electrocardiogram for the detection of obstructive sleep apnea, *IEEE Trans. Biomed. Eng.*, 50, 686–696.
- [42] de Chazal, P., Penzel, T. and Heneghan, C., 2004. Automated detection of obstructive sleep apnoea at different time scales using the electrocardiogram, *Physiol. Meas.*, 25, 967–983.
- [43] Mendez, M.O., Bianchi, A.M., Matteucci, M., Cerutti, S. and Penzel, T., 2009. Sleep Apnea screening by autoregressive models from a single ECG lead apnea study, *IEEE Trans. Biomed. Eng.*, 56, 2838–2850.
- [44] Mendez, M.O., Corthout, J., Van Huffel S., Matteucci, M., Penzel, T., Cerutti, S. And Bianchi, A.M., 2010. Automatic screening of obstructive sleep apnea from the ECG based on empirical mode decomposition and wavelet analysis, *Physiol. Meas.*, 31, 273–289.
- [45] Babaeizadeh, S., White, D.P., Pittman, S.D. and Zhou, S.H., 2010. Automatic detection and quantification of sleep apnea using heart rate variability, *Journal of Electrocardiology*, 43, 535–541.
- [46] Lweesy, K., Fraiwan, L., Khasawneh, N. and Dickhaus, H., 2009. New automated detection method of OSA based on artificial neural Networks using P-wave shape and time changes, *Journal of Medical Systems*, DOI 10.1007/s10916-009-9409-z.
- [47] Boudaoud, S.Heneghan, C., Rix, H., Meste, O. and O’Brien, C., 2005. P-wave shape changes observed in the surface electrocardiogram of subjects with obstructive sleep apnoea, *Computers in Cardiology*, 32, 359–362.
- [48] Maier, C., Dickhaus, H., Bauch, M. and Penzel, T., 2003. Comparison of heart rhythm and morphological ECG features in recognition of sleep apnea from the ECG, *Computers in Cardiology*, 30, 311–314.

- [49] Hossen, A., Ghunaimi, B.A. and Hassan, M.O., 2005. Subband decomposition soft-decision algorithm for heart rate variability analysis in patients with obstructive sleep apnea and normal controls, *Signal Processing*, 85, 95–106.
- [50] Khandoker, A.H., Karmakar, C. K. and Palaniswami, M., 2009a. Automated recognition of patients with obstructive sleep apnoea using wavelet-based features of electrocardiogram recordings, *Computers in Biology and. Medicine*, 39, 88–96.
- [51] Khandoker, A.H., Palaniswami, M. and Karmakar, C.K., 2009b. Support vector machines for automated recognition of obstructive sleep apnoea syndrome from electrocardiogram recordings, *IEEE Trans. Inf. Technol. Biomed. Eng.*, 13, 37–48.
- [52] del Campo, F., Hornero, R., Zamarron, C., Abasolo, D. and Alvarez, D., 2006. Oxygen saturation regularity analysis in the diagnosis of obstructive sleep apnea, *Artif. Intell. Med.*, 37, 111–118.
- [53] Hornero, R., Alvarez, D., Abasolo, D., del Campo, F. and Zamarron, C., 2007. Utility of approximate entropy from overnight pulse oximetry data in the diagnosis of obstructive sleep apnea syndrome, *IEEE Trans. Biomed.Eng.*, 54, 107–113.
- [54] Marcos, J.V., Hornero, R., Alvarez, D., del Campo, F. and Zamaron, C., 2009. Assessment of four statistical pattern recognition techniques to assist in obstructive sleep apnoea diagnosis from nocturnal oximetry, *Med. Eng. Phys.*, 31, 971–978.
- [55] Varady, P., Micsik, T., Benedek, S. and Benyo, Z., 2002. A novel method for the detection of apnea and hypopnea events in respiration signals, *IEEE Trans. Biomed. Eng.*, 49, 936–942.
- [56] Ragette, R., Wang, Y., Weinreich, G. and Teschler, H., 2010. Diagnostic performance of single airflow channel recording (ApneaLink) in home diagnosis of sleep apnea, *Sleep and Breathing*, 14, 109–114.
- [57] Liu, D., Pang, Z. and Lloyd, S.R., 2008. A neural network method for detection of obstructive sleep apnea and narcolepsy based on pupil size and EEG, *IEEE Trans. Neural Netw.*, 19, 308-318.
- [58] Basar, E., 1980. EEG-Brain Dynamics: Relation between EEG and evoked potentials, Elsevier, Amsterdam.
- [59] Bilir, E., 1999. Beyin elektriksel faaliyetinde nörolojik rahatsızlıklara bağlı değişiklikler, *TÜBİTAK Beyin Dinamigi Multidisipliner lisans üstü yaz okulu: Nörofizyoloji ve kognitif süreçlerde entegrasyon*, Ders Notu, Dicle Üni., Diyarbakır.
- [60] Tülay, E.E., 2009. Beyin elektriksel aktivitesinin ölçümü ve sinyal analizi, *Yüksek Lisans Tezi*, İ.K.Ü. Fen Bilimler Enstitüsü, İstanbul.

- [61] Silber M.H., Ancoli-Israel S., Bonnet M.H, et al., 2007. The visual scoring of sleep in adults, *Journal of Clinical Sleep Medicine*, 3:121-31.
- [62] Kolev, V., Yordanova, J., Basar-Eroglu, C. and Basar, E., 2002. Age effects on visual EEG responses reveal distinct frontal alpha networks, *Clinical Neurophysiology*, 113, 901–910.
- [63] Güntekin, B. and Basar, E., 2007a. Gender differences influence brain's beta oscillatory responses in recognition of facial expressions, *Neuroscience Letters*, 424, 94–99.
- [64] Güntekin, B. and Basar, E., 2007b. Brain oscillations are highly influenced by gender differences, *International Journal of Psychophysiology*, 65, 294–299.
- [65] Hayashi, H., Iijima, S., Sugita, Y., Teshima, Y., Tashiro, T., Matsuo, R., Yasoshima, A., Hishikawa, Y. and Ishihara, T., 1986. Appearance of frontal mid-line theta rhythm during sleep and its relation to mental activity, *Electroencephalogr. Clin. Neurophysiol.*, 66, 66-70.
- [66] Güntekin, B., Saatçi, E. and Yener, G., 2008. Decrease of evoked delta, theta and alpha coherence in alzheimer patients during a visual oddball paradigm, *Brain Research*, 1235, 109 –116.
- [67] Yener, G., Güntekin, B. and Basar, E., 2008. Event-related delta oscillatory responses of Alzheimer patients, *European Journal of Neurology*, 15, 540- 547.
- [68] Niedermeyer, E. and Lopes da Silva, F.H., 2005. *Electroencephalography: Basic Principles, Clinical Applications and Related Fields*, Lippincott Williams & Wilkins, Philadelphia.
- [69] <http://en.wikipedia.org/wiki/Electroencephalography>
- [70] Yazgan, E. ve Korürek, M., (1996). *Tip Elektroniği*, İ.T.Ü. Matbaası, İstanbul.
- [71] Öztürk, B., 2007. Yanıtına arayan eski bir soru: Niçin uyuyoruz?, *İ.Ü. İstanbul Tıp Fakültesi Dergisi*, 70,114-121.
- [72] Williams R.L., Karacan I. and Hirsch C.J., 1974. *Electroencephalography (EEG) of Human Sleep: Clinical Applications*, John Wiley & Sons Inc., New York.
- [73] Parrino, L., Ferri, R., Zucconi, M. and Fanfulla, F., 2009. Commentary from the Italian Association of Sleep Medicine on the AASM Manual for the Scoring of Sleep and Associated Events: for debate and discussion, *Sleep Medicine*, 10,799–808.
- [74] Barold S.S., 2003. Willem Einthoven and the birth of clinical electrocardiography a hundred years ago, *Cardiac Electrophysiology Review*, 7, 99-104.

- [75] Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology, 1996. Heart rate variability: Standards of measurement, physiological interpretation and clinical use, *European Heart Journal*, 17, 354 – 381.
- [76] Pehlivan, F., 1997. Biyofizik, Hacettepe Taş Kitapçılık, Ankara.
- [77] Köktürk, O., Tatlıcıoğlu, T., Kemaloğlu Y., Fırat, H. ve Çetin, N., 1997 Habitüel horlaması olan olgularda obstruktif sleep apne sendromu prevalansı, *Tüberküloz ve Toraks Dergisi*, 45, 7-11.
- [78] Davies, R.J.O. and Stradling J.R., 1996. The epidemiology of sleep apnoea, *Thorax*, 51, 65–70.
- [79] Çelik, O., 2002. Kulak Burun Boğaz Hastalıkları ve Baş Boyun Cerrahisi, Turgut Yayıncılık, İstanbul.
- [80] Köktürk, O., 2006. Uykuda solunum bozuklukları, *Türk Toraks derneği V Kış Okulu Notları*, Selçuk/İzmir.
- [81] Wu, H. and Yan-Go F., 1996. Self-reported automobile accidents involving patients with obstructive sleep apnea, *Neurology*, 46:1254-1257.
- [82] Loube, D.I., Gay, P.C., Strohl, K.P., et al., 1999. Indications for positive airway pressure treatment of adult obstructive sleep apnea patients: a consensus statement, *Chest*, 115, 863-866.
- [83] Gordon, P., and Sanders, M.H., 2005. Positive airway pressure therapy for obstructive sleep apnoea/hypopnoea syndrome, *Thorax*, 60, 68–75.
- [84] Köktürk, O., 1999. Uykunun izlenmesi (2) polisomnografi, *Tüberküloz ve Toraks dergisi*, 47, 499-511.
- [85] İtil, O., 2002. Uyku bozuklukları sınıflaması ve tanımlar, *Uyku Bozuklukları Toraks Derneği Okulu Merkezi Kurslar*, Ankara.
- [86] Raymond, B., Cayton, R.M., Bates, R.A., and Chappell, M.J., 2000. Screening for obstructive sleep apnoea based on the electrocardiogram, *Comput. Cardiol.*, 27, 267-270.
- [87] Yeha, Y. –C., and Wanga, W. –J., 2008. QRS complexes detection for ECG signal: The Difference Operation Method, *Computer methods and programs in biomedicine*, 91, 245-254.
- [88] Köhler, B.–U., Hennig, C., Orglmeister, R., 2002. The principles of software QRS detection, *IEEE Engineering in Medicine and Biology*, 21, 42-57.

- [89] Okada, M., 1979. A digital filter for the QRS complex detection, *IEEE Trans. Biomed. Eng.*, 26, 700-703.
- [90] Fraden, J. and Neumann, M.R., 1980. QRS wave detection, *Med. Biol. Eng. Comput.*, 18, 125-132.
- [91] Pan, J. and Tompkins, W.J., 1985. A real-time QRS detection algorithm, *IEEE Trans. Biomed. Eng.*, 32, 230-236.
- [92] Hamilton, P.S. and Tompkins, W.J., 1986. Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmic database, *IEEE Trans. Biomed. Eng.*, 33, 1157-1165, 1986.
- [93] Suppappola, S. and Sun, Y., 1994. Nonlinear transforms of ECG signals for digital QRS detection: A quantitative analysis, *IEEE Trans. Biomed. Eng.*, 41, 397-400.
- [94] Li, C., Zheng, C. and Tai, C., 1995. Detection of ECG characteristic points using wavelet transforms, *IEEE Trans. Biomed. Eng.*, 42, 21-28.
- [95] Bahoura, M., Hassani, M. and Hubin, M., 1997. DSP implementation of wavelet transform for real time ECG wave forms detection and heart rate analysis, *Comput. Methods Programs Biomed.*, 52, 35-44.
- [96] Kadambe, S., Murray, R. and Boudreaux-Bartels, G.F., 1999. Wavelet transform-based QRS complex detector, *IEEE Trans. Biomed. Eng.*, 46, 838-848.
- [97] Yıldız, A., Akın, M., ve Poyraz, M., 2010. EKG Kayıtlarından Tıkalıcı Uyku Apne Sendromunun Otomatik Teşhisi, *IEEE 18. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Diyarbakır.
- [98] Yıldız, A., Akın, M., ve Poyraz, M., 2011. An expert system for automated recognition of patients with obstructive sleep, *Expert Systems with Applications*, 38, 12880–12890
- [99] Turkoğlu, İ., 2002a. Durağan olmayan işaretler için zaman-frekans entropilerine dayalı akıllı örüntü tanıma, *Doktora Tezi*, F.Ü. Fen Bilimleri Enstitüsü, Elazığ.
- [100] Türkoğlu, İ., Arslan, A. ve İlkay, E., 2002b. A Computer aided method for diagnose of the heart mitral valve diseases, *International Journal for Engineering Modelling*, 15, 1- 9.
- [101] Sengur, A., 2008. An expert system based on principal component analysis, artificial immune system and fuzzy k–NN for diagnosis of valvular heart diseases, *Computers in Biology and Medicine*, 38, 329–338.
- [102] Übeyli, E.D., 2007. ECG beats classification using multiclass support vector machines with error correcting output codes, *Digital Signal Process.*, 17, 675-684.

- [103] Şengür, A., ve Türkoğlu, İ., 2003. Classifying analogue modulated communication signals using bayes decision criterion, S.Ü. *Fen Bilimleri Enstitüsü Dergisi*, 7, 32-36.
- [104] Avcı, E., Türkoğlu, İ., ve Poyraz, M., 2005. Intelligent target recognition based on wavelet packet neural network, *Expert Systems with Applications*, 29, 175-182.
- [105] Günal, S., 2008. Örüntü Tanıma Uygulamalarında Altuzay Analiziyle Öznitelik Seçimi ve Sınıflandırma, *Doktora Tezi*, E.O.Ü. Fen Bilimleri Enstitüsü, Eskişehir.
- [106] Aarabi, A., Wallois, F. and Grebe, R., 2006. Automated neonatal seizure detection: A multistage classification system through feature selection based on relevance and redundancy analysis, *Clinical Neurophysiology*, 117, 328-340.
- [107] Polikar, R., 2001. *The Wavelet Tutorial*, Available: <http://engineering.rowan.edu/~polikar/WAVELETS/WTtutorial.html>
- [108] Übeyli, E.D. and Güler, I., 2005. Improving medical diagnostic accuracy of ultrasound Doppler signals by combining neural network models, *Computers in Biology and Medicine*, 35, 533–554.
- [109] Mallat, S., 1989. A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Pattern Anal. and Machine Intell.*, 11, 674-693.
- [110] Strang, G. and Nguyen, T., 1996. *Wavelets and Filter Banks*, Wellesley, Cambridge, MA.
- [111] Ifeachor, E.C. and Jervis, B.W., 1993. *Digital Signal Processing: A Practical Approach*, Addison-Wesley publishing company Inc., U.S.
- [112] Proakis J.G. and Manolakis D.G., 1996. *Digital Signal Processing: Principles, Algorithms and Applications*, Prentice Hall Inc., New Jersey.
- [113] Shannon, C.E., 1948. A mathematical theory of communication, *Bell System Technical Journal*, 27, 623–656.
- [114] Tonga, S., Bezerianosa, A., Paula, J., Zhub, Y. and Thakora, N., 2002. Nonextensive entropy measure of EEG following brain in jury from cardiac arrest, *Elsevier Physica A*, 305, 619- 628.
- [115] Overwijk, M.H.F. and Reefman, D., 2000. Maximum-entropy deconvolution applied to electron energy-loss spectroscopy, *Pergamon Micron*, 31, 325-331.
- [116] Li, X., 2000. Edge directed statistical inference with applications to image processing, *Ph.D.Thesis*, Princeton Üniversitesi.
- [117] Kannathal, N., Choo, M. L., Acharya, U. R., and Sadasivan, P.K., 2005. Entropies for detection of epilepsy in EEG, *Computer Methods and programs in Biomedicine*, 80, 87-194.

- [118] Zhang, X.S. and Roy, R.J., 2001. Derived fuzzy knowledge model for estimating the depth of anesthesia, *IEEE Transactions on Biomedical Engineering*, 48, 312 - 323.
- [119] Mehta S.S., and Lingayat N.S., 2007. Development of Entropy based algorithm for cardiac beat detection in 12-lead electrocardiogram, *Signal processing*, 87, 3190-3201.
- [120] Hoang, M., Aaron, R. and Shiffman, C.A., 1997. Maximum entropy method for Magnetoencephalography, *IEEE Transactions on Biomedical Engineering*, 44, 98-102.
- [121] Coifman, R.R. and Wickerhauser, M.V., 1992. Entropy-based algorithms for best basis selection, *IEEE Transaction on Information Theory*, 38, 713-718.
- [122] Penny, W.D., 2000. *Signal Processing Course*, Lecture Notes.
- [123] Jang, S.R., 1993. ANFIS: Adaptive network-based fuzzy inference systems, *IEEE, Trans. On Man. and Cybernetics*, 23, 665-685.
- [124] Haykin, S., 1994. *Neural Networks, A Comprehensive Foundation*: Macmillan College Publishing Company Inc., New York.
- [125] Kil, D.H. ve Shin, F.B., 1996. *Pattern Recognition and Prediction with Applications to Signal Characterization*, AIP Press, New York.
- [126] Cristianini, N., Shawe-Taylor, J., 2000. *An Introduction to Support Vector Machines*, Cambridge University Press, Cambridge.
- [127] Theodoridis, S. and Koutroumbas, K., 2003. *Pattern recognition*, Academic Press, New York.
- [128] Öztemel E., 2003. *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul.
- [129] Tezel, G., 2007. *Biyomedikal İşaretlerin Yeni Bir Adaptif Aktivasyon Fonksiyonlu Yapay Sinir Ağı ile Sınıflandırılması*, *Doktora Tezi*, S.Ü. Fen Bilimleri Enstitüsü, Konya.
- [130] McCulloch, W. S., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity, *Bulletin Mathematics and Biophysics*, 5, 115-133.
- [131] Rumelhart, D.E., Hinton, D.E. and Williams, R.J., 1986. Learning representation by backpropagating errors, *Nature*, 323, 533-536.
- [132] Efe Ö. ve Kaynak O., 2000. *Yapay Sinir Ağları ve Uygulamaları*, Boğaziçi Üniversitesi, İstanbul.

- [133] Principe, J.C., Euliano, N.R., Lefebvre, W.C., 2000. Neural and Adaptive Systems: Fundamentals through Simulations, John Wiley & Sons Inc., New York.
- [134] Fauset, L., 1994. Fundamentals of Neural Networks, Prentice Hall, Englewood Cliffs, New Jersey.
- [135] Elmas, Ç., 2003. Bulanık mantık denetleyiciler, Seçkin Yayıncılık, Ankara.
- [136] Jang, J.S.R., Sun, C.T. and Mizutani, E., 1997. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence, Prentice-Hall, Englewood Cliffs, NJ.
- [137] Altınörs, A., 2007. Tip-II Bulanık Mantık ve Kayma Kipli Kontrol Yöntemleri ile Servo Sistemlerin Dayanıklı Kontrolü, *Doktora Tezi*, F. Ü. Fen Bilimleri Enstitüsü, Elazığ.
- [138] Akpolat, Z.H., 1999. Application of Fuzzy-Sliding Mode Control and Electronic Load Emulation to the Robust Control of Motor Drives, *Ph.D.Thesis*, University of Nottingham.
- [139] Vapnik, V.N., 1995. The Nature of Statistical Learning Theory, Springer-Verlag, New York.
- [140] Cortes, C. And Vapnik, V.N., 1995, Support vector networks, *Machine Learning*, 20, 273-297
- [141] Schölkopf, B., Sung, K., Burges, C., Girosi, F., Niyogi, P., Poggio, T., Vapnik, V., 1997. Comparing support vector machines with Gaussian kernels to radial basis function classifiers, *IEEE Trans. on Signal Processing*, 45, 2758–2765.
- [142] Smola, A., Schölkopf, B., 1998. On a kernel-based method for pattern recognition, regression, approximation and operator inversion, *Algorithmica*, 22 , 211–231.
- [143] Suykens, J. A. K., De Brabanter, J., Lukas, L. and Vandewalle, J., 2002. Weighted least squares support vector machines: Robustness and sparse approximation. *Neurocomputing*, 48, 85–105.
- [144] Çomak, E., 2008. Destek Vektör Makinelerinin Etkin Eğitimi için Yeni Yaklaşımlar, *Doktora Tezi*, S.Ü. Fen Bilimleri Enstitüsü, Konya.
- [145] Uçar, A., 2006. Destek Vektör Makine Tabanlı Bulanık Sistemler, Yeni Bir Gürbüz Sınıflayıcı ve Regresör Tasarımı, *Doktora Tezi*, F Ü. Fen Bilimleri Enstitüsü, Elazığ.
- [146] Lu, W., Wang, W., Leung A.Y.T., Lo, S.M., Yuen, R.K.K., Xu, Z., Fan, H., 2002. Air pollutant parameter forecasting using support vector machines, *IJCNN'02, Proceedings of the 2002 International Joint Conference on Neural Networks*.

- [147] Burges, C. J. C., 1998. A tutorial on support vector machines for pattern recognition, *Knowledge Discovery and Data Mining*, 2, 121–167.
- [148] Smola, A., Bartlett, P., Scholkopf, B. and Schuurmans, D., 2000. *Advances in Large Margin Classifiers*, MIT Press, Cambridge.
- [149] Song-yun, X., Wang, P.-W., Zhang, H.-J. and Zhao, H.-T., 2008. Research on the Classification of Brain Function Based on SVM, *2nd International Conference on Bioinformatics and Biomedical Engineering*, Shanghai, China.
- [150] Acir, N., 2006. A support vector machine classifier algorithm based on a perturbation method and its application to ECG beat recognition systems, *Expert Systems with Applications*, 31, 150–158.
- [151] Suykens, J.A.K. and Vandewalle, J., 1999. Least squares support vector machine classifiers, *Neural Processing Letters*, 9, 293–300.
- [152] Yildiz, A., Akin, M., Poyraz, M., and Kirbas, G., 2009. Application of adaptive neuro- fuzzy inference system for vigilance level estimation by using wavelet-entropy feature extraction, *Expert Systems with Applications*, 36, 7390–7399.
- [153] www.physionet.org.
- [154] de Chazal, P., Heneghan, C., Sheridan, E., Reilly, R., Nolan, P. and O'Malley, M., 2000. Automatic classification of sleep apnea epochs using the electrocardiogram, *Computers in Cardiology*, 27, 745–748.
- [155] Clifford, G.D., McSharry, P.E. and Tarassenko, L., 2002. Characterizing artefact in the normal human 24-h RR time series to aid identification and artificial replication of circadian variations in human beat to beat heart rate using a simple threshold, *Computers in Cardiology*, 29, 129–132.
- [156] Karmakar, C.K., Khandoker, A.H., & Palaniswami, M., 2007. Power spectral analysis of ECG signals during obstructive sleep apnoea hypopnoea Epochs, *In Proceedings of the 3rd international conference on intelligent sensors, sensor networks and information*, pp. 573–576.
- [157] Mateo, J. and Laguna, P., 2000. Improved heart rate variability signal analysis from the beat occurrence times according to the IPFM model, *IEEE Transactions on Biomedical Engineering*, 47, 985–996.
- [158] Kohavi, R., & Provost, F. (1998). Glossary of terms, *Editorial for the Special Issue on Applications of Machine Learning and the Knowledge Discovery process*, 30 (2/3).

ÖZGEÇMİŞ

Adı Soyadı: Abdulnasır YILDIZ

Doğum Tarihi: 1 Ocak 1972

Öğrenim Durumu:

Derece	Bölüm/ Üniversite	Yıl
Lisans	Elektrik-Elektronik Mühendisliği Bölümü, Dokuz Eylül Üniversitesi.	1992 - 1997
Yüksek Lisans	Elektrik-Elektronik Mühendisliği Bölümü, Fırat Üniversitesi	1999 - 2002
Doktora	Elektrik-Elektronik Mühendisliği Bölümü, Fırat Üniversitesi	2002 - ...

Yüksek Lisans Tez Başlığı ve Tez Danışmanı:

İki Doğru Akım Motorunun Aynı Yüğü Beslemesi Durumunun Bond Graf Yöntemiyle İncelenmesi,

Prof. Dr. Mustafa Poyraz

Görevler:

Görev Unvanı	Görev Yeri	Yıl
Uzman	Dicle Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü	1998 - ...